

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E
AMBIENTAL

UTILIZAÇÃO DO GOOGLE EARTH ENGINE PARA
MONITORAMENTO DA URBANIZAÇÃO NO DISTRITO
FEDERAL

GUILHERME TOLEDO RIVERO

ORIENTADOR: ELEUDO ESTEVES DE ARAUJO
SILVA JUNIOR

COORIENTADOR: BRUNO ESTEVES TÁVORA

MONOGRAFIA DE PROJETO FINAL 2 EM
ENGENHARIA AMBIENTAL

BRASÍLIA/DF: JULHO/2019

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E
AMBIENTAL**

**UTILIZAÇÃO DO GOOGLE EARTH ENGINE PARA
MONITORAMENTO DA URBANIZAÇÃO NO DISTRITO
FEDERAL**

GUILHERME TOLEDO RIVERO

**MONOGRAFIA DE PROJETO FINAL SUBMETIDA AO DEPARTAMENTO DE
ENGENHARIA CIVIL E AMBIENTAL DA UNIVERSIDADE DE BRASÍLIA
COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO
GRAU DE BACHAREL EM ENGENHARIA AMBIENTAL.**

APROVADA POR:

**ELEUDO ESTEVES DE ARAUJO SILVA JUNIOR, MSc (ENC/UNB)
(ORIENTADOR)**

**RICARDO TEZINI MINOTI, DSc (PTARH/ENC/UNB)
(EXAMINADOR INTERNO)**

**BRUNO RODRIGUES DE OLIVEIRA, MSc (UNB)
(EXAMINADOR EXTERNO)**

DATA: BRASÍLIA/DF, 10 DE JULHO DE 2019.

FICHA CATALOGRÁFICA

RIVERO, GUILHERME TOLEDO.

UTILIZAÇÃO DO GOOGLE EARTH ENGINE PARA MONITORAMENTO DA URBANIZAÇÃO NO DISTRITO FEDERAL.

xiii, 77 p., 297 mm (ENC/FT/UnB, Bacharel, Engenharia Ambiental, 2019)

Monografia de Projeto Final – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

- | | |
|---------------------------------------|-------------------------|
| 1. Google Earth Engine | 2. Geoprocessamento |
| 3. Sistema de Informações Geográficas | 4. Monitoramento Urbano |
| I. ENC/FT/UnB | II. Título (série) |

REFERÊNCIA BIBLIOGRÁFICA

RIVERO, G.T. (2019). *UTILIZAÇÃO DO GOOGLE EARTH ENGINE PARA MONITORAMENTO DA URBANIZAÇÃO NO DISTRITO FEDERAL*. Monografia de Projeto Final, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 77 p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Guilherme Toledo Rivero

TÍTULO DA MONOGRAFIA DE PROJETO FINAL: Utilização Do Google Earth Engine para Monitoramento da Urbanização no Distrito Federal.

GRAU / ANO: Bacharel em Engenharia Ambiental / 2019

É concedida à Universidade de Brasília a permissão para reproduzir cópias desta monografia de Projeto Final e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta monografia de Projeto Final pode ser reproduzida sem a autorização por escrito do autor.

GUILHERME TOLEDO RIVERO

guilherme.rivero@gmail.com

AGRADECIMENTOS

Agradeço primeiramente a mim mesmo, por ter perseverado para concluir este trabalho.

Agradeço aos meus pais pelo apoio que me deram ao longo da jornada. Eles foram fundamentais.

Muito grato também pela oportunidade de ter estudado na Universidade de Brasília.

Um agradecimento e cumprimento especial ao meu orientador prof. Eleudo Esteves, que mesmo com todas as responsabilidades dentro da própria UnB, esteve disposto a me ajudar e me orientar no projeto.

Agradeço também ao meu coorientador Bruno Esteves que teve a ideia inicial do projeto em relação à utilização do Google Earth Engine.

Gostaria de agradecer igualmente, ao prof. Ricardo Minoti e ao geólogo Bruno por terem aceitado compor a banca de avaliação deste Projeto Final em Engenharia Ambiental.

E, por fim, um agradecimento a todos os amigos e familiares que me suportaram e compreenderam esses momentos finais de tensão, estresse e ansiedade. Com certeza sem esse apoio, eu não teria conseguido.

Todo o esforço é recompensado!

RESUMO

UTILIZAÇÃO DO GOOGLE EARTH ENGINE PARA MONITORAMENTO DA URBANIZAÇÃO NO DISTRITO FEDERAL

O presente trabalho tem como objetivo principal a utilização de geotecnologias com ênfase da plataforma Google Earth Engine (GEE) para o monitoramento da urbanização, avaliação ambiental e apoio ao planejamento urbano no Distrito Federal (DF). A partir da revisão de uma série de índices de vegetação, o trabalho apresenta os resultados gerados no GEE a fim de verificar a sua coerência e potencialidade quando comparados a uma ferramenta de Sistema de Informações Geográficas tradicional. Para validar essa comparação, utilizou-se a ferramenta QGIS para o cálculo do índice de vegetação mais utilizado atualmente para avaliar a vegetação, o Índice de Vegetação por Diferença Normalizada. A partir dos resultados do QGIS e GEE foi possível verificar que esta ferramenta livre (pelo menos até o presente momento) pode ser considerada confiável, não somente para o monitoramento da urbanização no DF, mas também para monitorar estoques de carbono no solo, áreas de desmatamento, dentre diversas outras análises.

Palavras-chave: Google Earth Engine, Geoprocessamento, Sistema de Informações Geográficas, Monitoramento Urbano, Índices de Vegetação.

ABSTRACT

USING GOOGLE EARTH ENGINE FOR MONITORING THE URBANIZATION IN FEDERAL DISTRICT

The actual project has as its main objective the use of geotechnologies with emphasis of the Google Earth Engine (GEE) platform for monitoring, environmental evaluation and support to urban planning in the Federal District. From a review of a series of vegetation indexes, the paper presents the results generated in the GEE to verify its coherence and potentiality when compared to a traditional Geographic Information System tool. To validate this analogy, it was used the QGIS tool to calculate the most employed index currently, the Normalized Difference Vegetation Index. From QGIS and GEE results was possible to verify that this free tool (at least until the present moment) can be considerably trustable, not only for urban monitoring onto Federal District, but also for monitoring carbon's stock in soil, deforestation areas and, many other analyses.

Keywords: Google Earth Engine, Geoprocessing, Geographic Information System, Urban Monitoring, Vegetation Indexes.

SUMÁRIO

1. INTRODUÇÃO.....	1
2. OBJETIVOS.....	3
2.1 OBJETIVO GERAL	3
2.2 OBJETIVOS ESPECÍFICOS.....	3
3. FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA	4
3.1 SENSORIAMENTO REMOTO	4
3.1.1 Composição RGB.....	4
3.1.2 Resoluções das Imagens.....	6
3.1.2.1 Resolução Espacial	7
3.1.2.2 Resolução Espectral	8
3.1.2.3 Resolução Radiométrica	10
3.1.2.4 Resolução Temporal	10
3.1.3 Índices de Vegetação.....	11
3.1.3.1 Índice de Umidade por Diferença Normalizada (NDWI).....	12
3.1.3.2 Índice de Vegetação Perpendicular (PVI)	13
3.1.3.3 Índice Conteúdo de Água Foliar (LWCI).....	13
3.1.3.4 Índice de Vegetação Ajustado ao Solo (SAVI)	13
3.1.3.5 Índice de Vegetação Resistente à Atmosfera (ARVI)	14
3.1.3.6 Índice de Vegetação Resistente à Atmosfera e aos Solos (SARVI).....	14
3.1.3.7 Índice de Vegetação Livre de Aerossol (AFRI)	15
3.1.3.8 Índice de Vegetação Realçado (EVI)	16
3.1.3.9 Índice de Vegetação Triangular (TVI)	16
3.1.3.10 Razão Simples Reduzida (RSR)	17
3.1.3.11 Índice de Reflectância para Absorção pela Clorofila (CARI); Índice de Reflectância para Absorção pela Clorofila Modificado (TCARI); Índice Otimizado de Vegetação Ajustado a Solos (OSAVI); Razão TCARI/OSAVI	17
3.1.3.12 Índice Resistente à Atmosfera no Visível (VARI)	19
3.1.3.13 Índice por Diferença Normalizada para Áreas Construídas (NDBI)..	19
3.1.3.14 Novo Índice de Vegetação (NVI)	20
3.1.3.15 Determinação da Posição da Borda Vermelha (REP)	20
3.1.4 Os Satélites Landsat e Sentinel	21

3.1.5 Shuttle Radar Topography Mission (SRTM)	24
3.1.6 The Tropical Rainfall Measuring Mission (TRMM)	25
3.2 GEOPROCESSAMENTO	25
3.2.1 Sistema de Informações Geográficas	25
3.2.2 Google Earth Engine	25
3.2.3 Programas de SIG Tradicionais.....	26
3.3 Planejamento Urbano.....	27
3.3.1 Expansão Urbana.....	27
3.3.2 Zoneamento Ecológico-Econômico do Distrito Federal (ZEE-DF)	27
4. MATERIAIS E MÉTODOS	29
4.1 ÁREA DE ESTUDO	29
4.2 MATERIAIS.....	30
4.2.1 Equipamento.....	30
4.2.2 Banco de Dados.....	30
4.3 METODOLOGIA.....	31
4.3.1 Procedimentos Gerais de um SIG Tradicional	32
4.3.2 Aplicação do Google Earth Engine (GEE)	33
4.3.3 Procedimentos Gerais no GEE.....	37
4.3.4 Principais Atalhos no GEE.....	38
4.3.5 Utilização da Coleção de Imagens	39
4.3.6 Função para Remoção de Nuvem.....	41
4.3.7 Exportação de Imagens no GEE.....	42
4.3.8 Comparação das Ferramentas.....	43
5. RESULTADOS E DISCUSSÃO	44
5.1 PRIMEIRO TESTE: NDVI IMAGEM MODIS	44
5.2 MODELO DIGITAL DE ELEVAÇÃO – SRTM PARA O DF.....	45
5.3 ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA – NDVI PARA O DF	46
5.4 ÍNDICE DE VEGETAÇÃO AJUSTADO – EVI PARA O DF	47
5.5 ÍNDICE DE VEGETAÇÃO AJUSTADO AO SOLO – SAVI PARA O DF	48
5.6 ÍNDICE DE ÁGUA – NDWI PARA O DF.....	49
5.7 DIFERENÇA NORMALIZADA PARA ÁREAS CONSTRUÍDAS – NDBI PARA O DF	50

5.7.1 NBDI com as Imagens do Landsat 7	51
5.7.2 NBDI com as Imagens do Landsat 8.....	52
5.7.3 NBDI com as Imagens do Sentinel – 2A.	54
5.8 COMPARAÇÃO DAS FERRAMENTAS QGIS E GEE	55
5.9 VANTAGENS E DESVANTAGENS DO USO DA FERRAMENTA GEE	57
6. CONCLUSÕES	60
REFERÊNCIAS BIBLIOGRÁFICAS.....	62
APÊNDICES.....	68

LISTA DE FIGURAS

Figura 3.1 Processo de formação de cores. (FLORENZANO, 2011)	5
Figura 3.2 Fotografia aérea colorida natural (a) e fotografia colorida infravermelha (b). (FLORENZANO, 2011).....	6
Figura 3.3 Diferenciação entre cultura de trigo sadia (vermelho mais claro) e doente (vermelho mais escuro). (FLORENZANO, 2011)	6
Figura 3.4 Imagens de diferentes sensores e resoluções espaciais para discriminar áreas urbanas: região Leste da cidade de São Paulo. (MELO, 2002).....	8
Figura 3.5 Espectro Eletromagnético (A) e Resolução espectral (B). (MELO, 2002).....	9
Figura 3.6 Diferença de resolução radiométrica, área urbana: região nordeste da cidade de São Paulo	10
Figura 3.7 Comparação da Janela Espectral entre Landsat e Sentinel. (ESA, 2018)	23
Figura 3.8 Mapa do Macrozoneamento do Distrito Federal, do ZEE – DF.	29
Figura 4.1 Mapa de Localização da Área de Estudo – DF.	30
Figura 4.2 Passos para um processamento em um SIG tradicional.	33
Figura 4.3 Página Inicial do Google Earth Engine.	34
Figura 4.4 Página de <i>script</i> do GEE e suas funcionalidades (GOOGLE, 2017).	36
Figura 4.5 NDVI gerado a partir de imagens do satélite MODIS para a região do DF.	36
Figura 4.6 Criação da <i>Fusion Table</i> no <i>Google Drive</i>	37
Figura 4.7 Visualização de parâmetros da imagem, Sentinel – 2A_RGB.....	37
Figura 4.8 Comparação da imagem sem realce (A) e com realce (B), imagem Sentinel – 2A.	38
Figura 4.9 Utilização janela de ajuda GEE com o exemplo para o uso do <i>clip</i>	39
Figura 4.10 Utilização do atalho para rodar o código.	39
Figura 4.11 Utilização do atalho para alteração múltipla.....	39
Figura 4.12 Declaração de variável para importação de imagem única e de uma coleção de imagem.	40

Figura 4.13 Busca de coleções de imagens do satélite Landsat.	41
Figura 4.14 Busca de coleções de imagens do satélite Sentinel.	41
Figura 4.15 Em A tem-se a composição RGB sem a função de remoção de nuvens, em B tem-se a mesma imagem composta, contudo com a função de remoção de nuvens, ambas para o Sentinel – 2A.	42
Figura 4.16 Em A tem-se a composição RGB sem a função de remoção de nuvens, em B tem-se a mesma imagem composta, contudo com a função de remoção de nuvens, ambas para o Landsat 8.	42
Figura 4.17 Exportação de uma imagem RGB do satélite Landsat 8.	43
Figura 5.1 NDVI gerado para a imagem do Satélite MODIS.	44
Figura 5.2 SRTM gerado para o DF.	45
Figura 5.3 Visualização dos parâmetros gerados do SRTM para o DF.	45
Figura 5.4 NDVI gerado para o DF.	46
Figura 5.5 Visualização dos parâmetros do NDVI para o DF.	47
Figura 5.6 EVI gerado para o DF.	47
Figura 5.7 Visualização dos parâmetros do EVI para o DF.	48
Figura 5.8 SAVI gerado para o DF.	48
Figura 5.9 Visualização dos parâmetros de SAVI para o DF.	49
Figura 5.10 NDWI gerado para o DF, mês de julho 2018.	49
Figura 5.11 NDWI gerado para o DF, mês de dezembro 2018.	50
Figura 5.12 NBDI gerado para o DF a partir de imagens do satélite Landsat 7, 2000.	51
Figura 5.13 NBDI gerado para o DF a partir de imagens do satélite Landsat 7, 2010.	51
Figura 5.14 NBDI gerado para o DF a partir de imagens do satélite Landsat 7, 2019.	52
Figura 5.15 NBDI gerado para o DF a partir de imagens do satélite Landsat 8, 2013.	53
Figura 5.16 NBDI gerado para o DF a partir de imagens do satélite Landsat 8, 2017.	53
Figura 5.17 NBDI gerado para o DF a partir de imagens do satélite Landsat 8, 2019.	54
Figura 5.18 NBDI gerado para o DF a partir de imagens do satélite Sentinel – 2A.	54

Figura 5.19 Mapa do NDVI gerado para o DF com o uso do QGIS	56
Figura 5.20 Mapa do NDVI gerado para o DF com o uso do QGIS para a imagem do GEE.	56
Figura 5.21 Passos para um processamento no GEE.....	59

LISTA DE TABELAS

Tabela 3.1 Comparação entre os satélites Landsat 8 e Sentinel-2 (Adaptado de ENGESAT, 2015).....	23
Tabela 5.1 Comparações entre as ferramentas QGIS e GEE.	55
Tabela 5.2 Tabela de vantagens e desvantagens da ferramenta GEE.....	57

1. INTRODUÇÃO

O uso de geotecnologias faz-se cada vez mais presente no cotidiano de usuários de todo o planeta. Há uma necessidade constante de obtermos informações rapidamente do mundo todo, em grande parte, com o intuito de tentar prever catástrofes naturais por meio do monitoramento de imagens de satélite em tempo real, no entanto, essas imagens também podem ser usadas para monitoramentos locais ou regionais específicos, como por exemplo, áreas de supressão de flora e áreas de expansão urbana. Além disso, as técnicas e processamentos proporcionados por um Sistema de Informações Geográficas (SIG) permitem que esses dados sejam analisados e visualizados em formatos de mapas para que sejam avaliados. Contudo, devido à elevada taxa de crescimento da quantidade de tais dados, tanto a análise quanto a interação com esse *Big Data* têm sofrido alterações ao longo dos anos.

Atualmente, a necessidade de adquirir esses dados rapidamente tem aumentado muito e, isso faz com que a capacidade de processamento dos computadores seja cada vez mais demandada. Sabendo-se dessa demanda elevada, a plataforma *Google Earth Engine* mostra que é possível realizar processamentos consideravelmente mais rápidos que um SIG tradicional. A partir de uma base catalográfica de vários *petabytes* de imagens de satélite na nuvem, ou seja, o usuário pode realizar diversos processamentos de imagens sem necessitar de um computador extremamente dependente de memória de processamento disponível para tal. Todo o processamento é feito em rede direta com a base de dados na nuvem, fazendo-se necessária apenas uma conexão com a internet.

A partir da necessidade de um monitoramento mais preciso nas cidades, tem-se utilizado as ferramentas SIG para verificar e avaliar a urbanização. Nesse sentido, as imagens temporais auxiliam na interpretação e identificação de áreas urbanizadas. Mediante essas imagens, pode-se verificar quais mudanças tiveram ao longo do tempo analisado. Ao considerar uma série temporal de imagens é possível identificar o crescimento da urbanização e, por meio dela, verificar se as expansões estão seguindo o plano de ordenamento territorial. Portanto, o uso do geoprocessamento e das ferramentas SIG mostra-se essencial para o monitoramento e planejamento urbano.

O presente trabalho traz como possível alternativa às ferramentas de SIG tradicionais a ferramenta GEE. Por meio dela realizam-se praticamente todas as funcionalidades do SIG tradicional. Uma grande vantagem que se pode perceber no GEE é

em relação ao seu processamento ser todo *online*, dessa forma, evita-se o uso do processamento dos computadores exigidos por uma ferramenta de SIG tradicional. Para as comparações utilizou-se o programa QGIS.

Considerando-se as funcionalidades de um SIG tradicional, foi possível identificar que a ferramenta GEE apresenta praticamente as mesmas aplicabilidades. Pode-se citar as possibilidades de correções de ruído na imagem, como por exemplo, nuvens. Além da possibilidade da realização de ajustes dos parâmetros de maneira intuitiva através da janela de parâmetros, semelhante á janela de atributos no caso do QGIS.

A ferramenta GEE apresenta uma grande vantagem em relação aos programas de SIG tradicionais, que é a condição de ter uma vasta base de dados que conta com imagens de diversos satélites. Ou seja, para realizar um processamento o usuário somente precisa escolher a coleção de imagens que deseja importar e colocar na página de *script* do GEE, sem a necessidade de baixar o conjunto de imagens.

Para avaliar as potencialidades do GEE calculou-se uma série de índices de vegetação na delimitação geográfica do DF com o intuito de monitorar a urbanização e, conseqüentemente, as áreas de supressão de flora. Esses índices foram calculados utilizando-se imagens dos satélites Landsat 7, Landsat 8 e Sentinel – 2A da base de dados do próprio GEE. Comparou-se também a ferramenta GEE com a ferramenta QGIS, a fim de comprovar os resultados gerados para a região do DF. Dessa forma, o objetivo principal desse trabalho foi verificar a potencialidade da ferramenta GEE para a avaliação ambiental e apoio ao planejamento urbano no Distrito Federal (DF).

2. OBJETIVOS

2.1 OBJETIVO GERAL

Utilização de geotecnologias com ênfase da plataforma *Google Earth Engine* (GEE) para o monitoramento, avaliação ambiental e apoio ao planejamento urbano no Distrito Federal (DF).

2.2 OBJETIVOS ESPECÍFICOS

- i. Programar o código do Índice por Diferença Normalizada para Áreas Construídas para o sistema GEE, que auxilie no monitoramento da urbanização no DF.
- ii. Avaliar os ganhos e benefícios do sistema GEE comparando-se com o *software* QGIS.
- iii. Identificar/Analisar as potencialidades e usos da ferramenta GEE para a engenharia Ambiental.
- iv. Verificar como o GEE facilita a análise ambiental a partir dos índices de vegetação.

3. FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA

3.1 SENSORIAMENTO REMOTO

A partir do advento das técnicas de cartografia e geoprocessamento, pode-se verificar que o sensoriamento remoto é uma das técnicas mais importantes e utilizadas atualmente. Com a utilização de seus princípios e conceitos, diversos *softwares* foram criados para facilitar seus usos e aplicações. O sensoriamento é uma das técnicas que possibilitou a obtenção de imagens da superfície terrestre de forma remota. Contudo, de acordo com Meneses e Almeida (2012) a definição mais clássica de sensoriamento remoto pode ser definida por: “Sensoriamento remoto é uma técnica de obtenção de imagens dos objetos da superfície terrestre sem que haja um contato físico de qualquer espécie entre o sensor e o objeto”.

Outra definição mais específica, de acordo com Fitz (2008) pontua que sensoriamento remoto é “a técnica que utiliza sensores para a captação e registro à distância, sem o contato direto, da energia refletida ou absorvida pela superfície terrestre.” Para a aquisição das informações pelos sensores, se faz necessária à presença de três elementos básicos, sendo eles: fonte ou energia radiante, objeto de visada e sistema de imageamento óptico e detector.

De forma complementar às duas definições, de acordo com Colwell (1983), sensoriamento remoto pode ser definido como a medição ou aquisição de informação de alguma propriedade de um objeto ou fenômeno, por um dispositivo de registro que não esteja em contato físico com o objeto ou fenômeno de estudo.

A partir das definições mais formais de sensoriamento remoto têm-se outras definições e conceitos que fazem parte da temática e colaboram para o tema em questão. Nos tópicos seguintes, estas definições são apresentadas de forma a contribuir às análises acerca da temática.

3.1.1 Composição RGB

O processamento da composição colorida das imagens de satélite ou fotográficas utiliza o princípio da formação primária das cores. Ou seja, a partir das cores vermelho (*red*), verde (*green*) e azul (*blue*) pode-se gerar uma composição colorida RGB.

Existem dois processos de formação de cores, o aditivo e o subtrativo. No processo aditivo são formadas as cores amarela, ciano e magenta. A cor amarela é formada a partir da mistura da cor verde com a vermelha. A cor ciano a partir da mistura do verde com o azul e a cor magenta, da mistura do vermelho com o azul. O branco é gerado pela combinação das três cores primárias em proporções iguais (FLORENZANO, 2011).

Já no processo subtrativo, que é o mais utilizado, ocorrem as formações das cores a partir de três filtros em frente a uma fonte luminosa branca. O filtro amarelo absorve a luz azul do feixe de luz branca e transmite a verde e a vermelha. O filtro magenta absorve a luz verde e transmite a azul e a vermelha. O filtro ciano absorve o componente vermelho e transmite o verde e o azul. A superposição dos filtros magenta e ciano, mostrada no diagrama, permite a passagem da luz azul, pois o filtro magenta absorve o verde e o ciano absorve o vermelho. A superposição do amarelo e ciano e do amarelo e magenta gera as cores verde e vermelha, respectivamente. A superposição dos três filtros impede a passagem da luz, absorvendo as três cores primárias presentes na luz branca, e a ausência de cor gera o preto. Tal processo é ilustrado pela figura 3.1.




Figura 3.1 Processo de formação de cores. (FLORENZANO, 2011)

Além da possibilidade da composição RGB, também podem ser compostas imagens coloridas utilizando-se filmes fotográficos sensíveis à região do infravermelho. A tonalidade ou a cor das imagens dependerá da sensibilidade do filme e dos filtros utilizados. Utilizando-se um filme infravermelho preto e branco obtém-se uma imagem pancromática e utilizando-se um filme infravermelho colorido obtêm-se imagens denominadas falsa-cor. Nas figuras 3.2 e 3.3 pode-se observar a diferenciação entre uma

fotografia aérea colorida natural (a) e uma colorida infravermelha (b). Na imagem infravermelha a vegetação natural é representada em vermelho e a vegetação artificial ou objetos verdes são representados pelas cores verde/azul. As imagens infravermelhas auxiliam, portanto, a identificar a fitossanidade das culturas e a umidade do solo.




Figura 3.2 Fotografia aérea colorida natural (a) e fotografia colorida infravermelha (b). (FLORENZANO, 2011)




Figura 3.3 Diferenciação entre cultura de trigo sadia (vermelho mais claro) e doente (vermelho mais escuro). (FLORENZANO, 2011)

3.1.2 Resoluções das Imagens

Segundo Meneses e Almeida (2012), sempre estão presentes duas questões acerca das aplicações com uso de geotecnologias, a primeira questão se refere à qual resolução de imagem seria melhor representar, identificar ou resolver os objetos de interesse e, a outra se refere à escala. Ou seja, qual seria a melhor escala para reproduzir os objetos ou fenômenos geográficos.

Existem quatro representações em termos de resolução:

1. Espacial
2. Espectral
3. Radiométrica
4. Temporal

A resolução Espacial leva em conta a área do campo de visada do sensor. A Espectral, a partir do comprimento de onda das bandas. A Radiométrica utiliza os valores numéricos da medida da radiância do alvo. E, por último, a resolução Temporal é a diferença ou intervalo de tempo entre a obtenção de imagens.

3.1.2.1 Resolução Espacial

A resolução espacial refere-se à habilidade do sistema sensor em distinguir e medir os alvos. Esta habilidade baseia-se na projeção geométrica do detector na superfície terrestre, definindo a sua área do campo de visada do instrumento numa certa altitude e num determinado instante. O ângulo definido por esta projeção é denominado de campo de visada instantânea (*Instantaneous Field Of View* – IFOV). O IFOV define a área do terreno focalizada a uma dada altitude pelo instrumento sensor. Os sensores heliosíncronos têm uma altitude fixa com relação à superfície terrestre, que corresponde ao tamanho da unidade mínima de informação da imagem, denominada de pixel (*picture element*, derivado do inglês), ou “dot”, como é conhecido na engenharia civil (VINCENT, METCALFE e TONG, 1996).

Contudo, a escala a ser utilizada dependerá da intenção que se deseja para determinada imagem ou estudo. Por exemplo, podem ser usadas imagens de pequena resolução espacial (30, 20 metros) para escalas regionais, onde não há a necessidade de apresentar imagens com detalhes extremos. Caso seja necessária a apresentação de imagens com maiores detalhes utiliza-se resoluções espaciais grandes (1 a 0,5 metro). Os satélites Landsat e CBERS, por exemplo, realizam imagens com resoluções menores. Já as imagens do Ikonos e Orbview são de resoluções maiores. Já os satélites Sentinel-2 e SPOT 4 promovem imagens de resolução média (10 metros). Portanto, quanto maior a resolução espacial, maior o nível de detalhes perceptível na imagem, desde que o sinal de saída de um detector esteja relacionado com a média da energia radiante dentro da área projetada. (MELO, 2002)

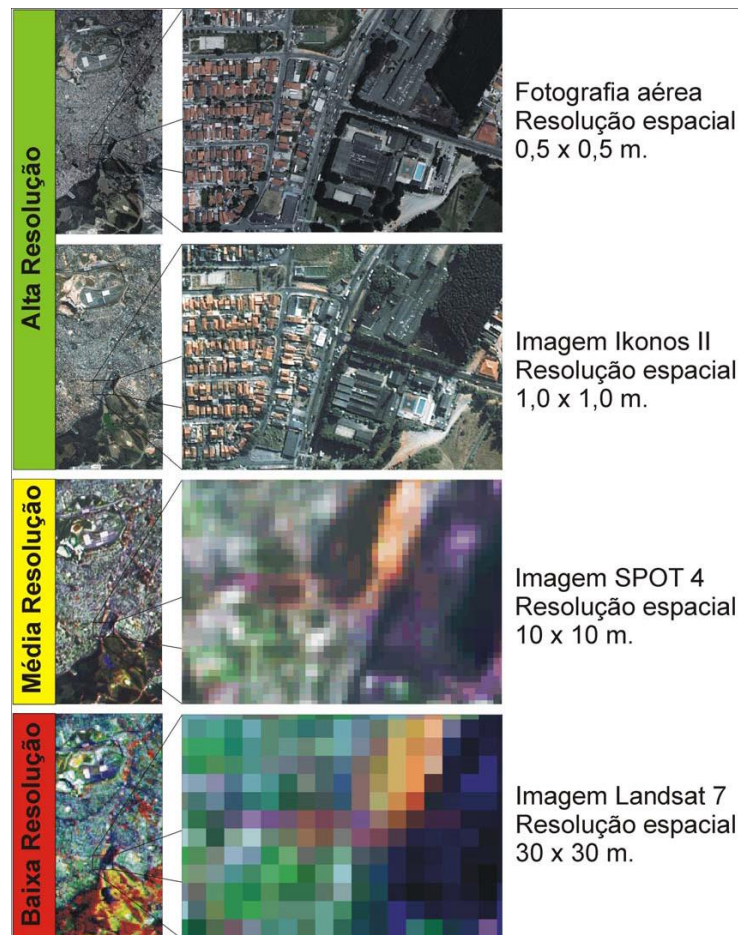


Figura 3.4 Imagens de diferentes sensores e resoluções espaciais para discriminar áreas urbanas: região Leste da cidade de São Paulo. (MELO, 2002)

3.1.2.2 Resolução Espectral

Segundo Novo (1988), resolução espectral é “uma medida da largura das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade do sinal de retorno”. Somente sistemas sensores denominados de multiespectrais abordam esse tipo de resolução (MELO, 2002). Na figura 3.5 (A), pode-se observar de maneira ilustrativa o conceito de resolução espectral. Na ilustração A tem-se a distribuição do espectro eletromagnético e especial destaque para a região do visível que varia de 0,4 a 0,7 μm em comprimento de onda. Na figura 3.5 (B), tem-se a comparação entre dois sistemas sensores (vermelho e azul) em que o sistema sensor em vermelho apresenta maior número de bandas e menor largura do intervalo em relação ao sistema sensor azul. Já o sistema sensor azul apresenta menor quantidade de bandas e menor sensibilidade espectral. Portanto, com uma menor quantidade de bandas e menor largura do intervalo, maior é a resolução espectral. Comparando os dois sistemas sensores, verifica-se que o primeiro pode caracterizar e distinguir melhor um objeto na imagem do que o outro

sistema. Portanto, quanto menor o número de bandas e menor a largura do intervalo, maior a discriminação do alvo na cena e melhor a resolução espectral.

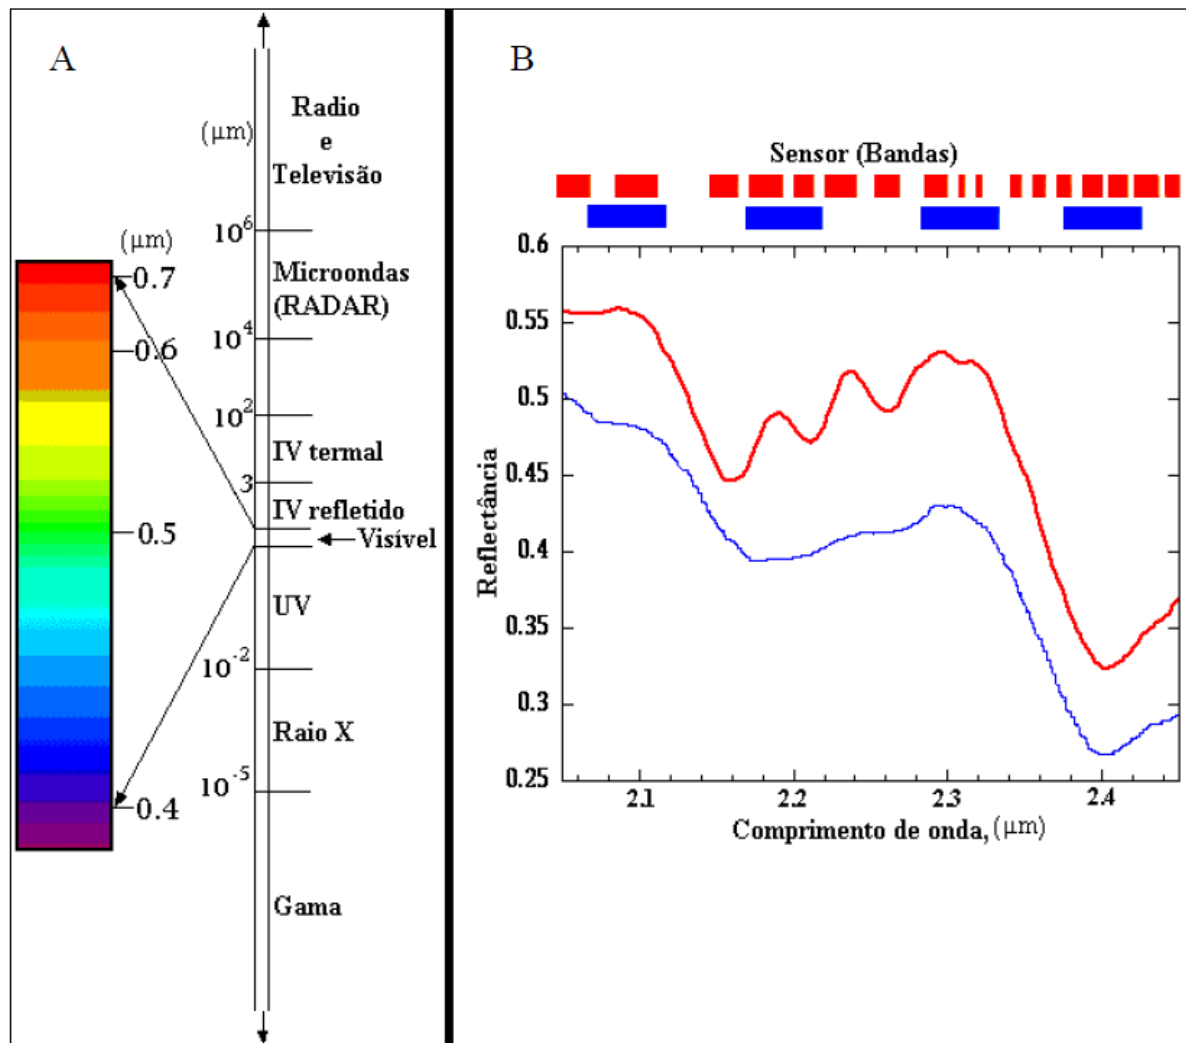


Figura 3.5 Espectro Eletromagnético (A) e Resolução espectral (B). (MELO, 2002)

3.1.2.3 Resolução Radiométrica

Resolução Radiométrica é a capacidade em que o sistema sensor apresenta para detectar as variações da radiância espectral obtida. De acordo com Schowengerdt (1983), existe uma definição chamada Número Digital (ND), em que a radiância de cada pixel passa por uma codificação digital. Esse valor é expresso em *bits* e pode ser traduzido para uma intensidade visual ou nível de cinza que varia num intervalo finito (0, K-1), onde K é a quantidade de valores possíveis. Este intervalo é denominado de níveis de quantização.

O valor do intervalo é sempre expresso em potência de 2, já que os níveis são em *bits* (*binary digits* - número de dígitos binários), ou seja, 1 *bit*, por exemplo é $2^1 = 2$, 2 *bits* é $2^2 = 4$, 4 *bits* é $2^4 = 16$, 8 *bits* é $2^8 = 256$ (equivalente a um *byte*) e assim por diante. A figura 3.6 ilustra a resolução radiométrica em diferentes bits, contudo, quanto maior o número de bits, maior a capacidade de armazenagem e, conseqüentemente, melhor a resolução.

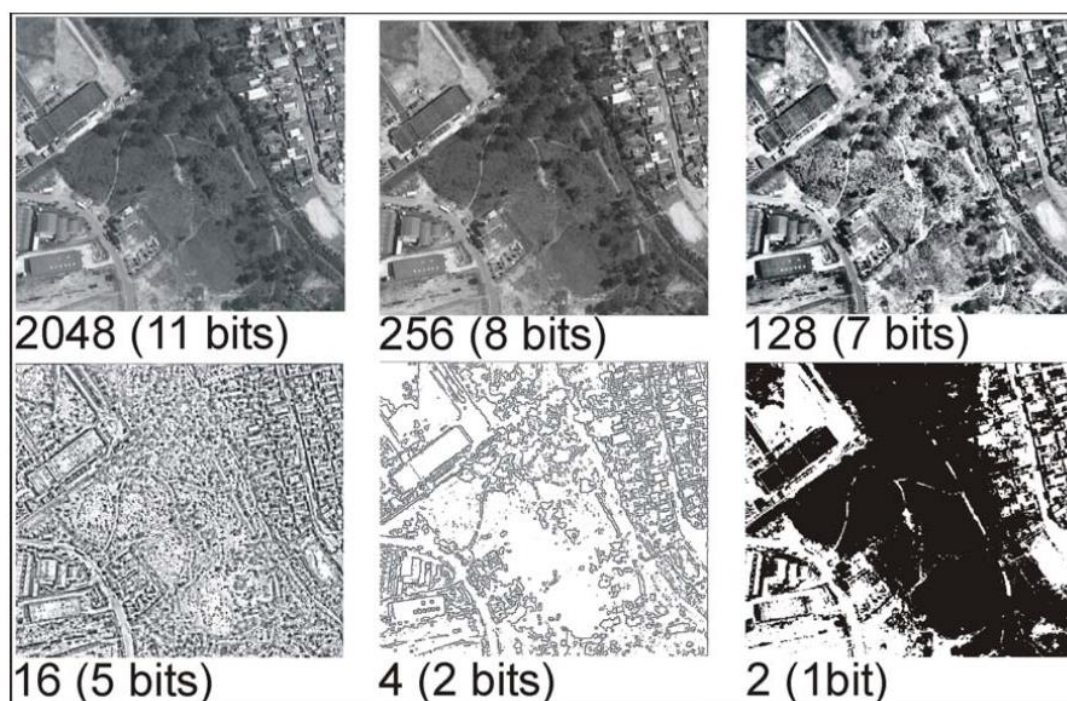


Figura 3.6 Diferença de resolução radiométrica, área urbana: região nordeste da cidade de São Paulo

(MELO, 2002)

3.1.2.4 Resolução Temporal

O conceito de resolução temporal refere-se à frequência de passagem do sensor num mesmo local, num determinado intervalo de tempo. Este ciclo está relacionado às características orbitais da plataforma (altura, velocidade, inclinação), e ao ângulo total de

abertura do sensor. A partir dessa forma de resolução é possível analisar as mudanças na superfície terrestre por meio das séries históricas das imagens. Tal análise é bastante útil para a verificação de áreas de expansão urbana, por exemplo.

O que torna essa resolução interessante é o relacionamento entre as resoluções, por exemplo, a interação entre resoluções temporal e radiométrica permite que existam funções particulares a depender da finalidade. Contudo, quanto maior a resolução das imagens maior será a quantidade de dados a ser processado.

3.1.3 Índices de Vegetação

O índice de vegetação permite que seja possível a análise espectral a partir da densidade da cobertura vegetal, este segue o princípio da divisão de bandas. À respeito dos tipos de índices utilizados no processamento de imagens existem dois índices bastante conhecidos, o índice de vegetação por diferença *Ratio Vegetation Index* – *RVI* e o índice de vegetação por diferença normalizada: *Normalized Difference Vegetation Index* – *NDVI*. O índice *RVI* é dado pela diferença entre a banda situada no infravermelho próximo (*NIR*), que representa a área onde a vegetação apresenta mais intensa refletância e, a banda situada no vermelho (*RED*), região de mais alta absorção da luz visível por parte da vegetação. Esse índice pode ser representado pela equação a seguir:

$$RVI = \frac{NIR}{RED}$$

Equação (3.1)

A partir da necessidade de se expor a imagem final ao usuário/interprete, é necessário que haja um escalonamento para que se convertam os valores da divisão para números inteiros dentro do intervalo numérico da imagem (por ex. 0 – 255). Contudo, os valores absolutos de *RVI* computados são sempre maiores que zero e assumem valores positivos altos em áreas de densa cobertura vegetal. O resultado é uma imagem monocromática, com a gradação de tons de cinza indicando a variação da biomassa ou o índice de área foliar. Quanto mais claro o tom de cinza, maior a densidade de vegetação. Tons de cinzas médios indicam pouca vegetação e tons de cinza totalmente escuros indicam ausência de vegetação, o que só pode ocorrer nas áreas de corpos de água, de solos expostos, áreas cobertas por neve, ou nuvens (MENESES e ALMEIDA, 2012).

Complementando-se o RVI, existe o NDVI. São similares, porém o NDVI é um pouco mais complexo. Este índice envolve a diferença e a soma entre estas duas bandas do infravermelho próximo e do vermelho, segundo a razão:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Equação (3.2)

O NDVI que for computado varia de -1 a +1. O NDVI possui uma vantagem sobre o RVI, pois existe uma tendência que ele seja linearmente mais proporcional à biomassa. Além disso, quando se deseja realizar comparações temporais ele sofre menos interferências atmosféricas. Contudo, esse índice é amplamente utilizado em escala comercial (sensores SPOT) e possui uma versatilidade muito grande em diversos aspectos de análise da vegetação, podendo-se citar alguns deles: medida de índice de área foliar, determinação da porcentagem de cobertura do solo, e estimativas da radiação fotossinteticamente ativa, que foram usados em vários modelos para estudos de fotossíntese e sequestro de carbono.

3.1.3.1 Índice de Umidade por Diferença Normalizada (NDWI)

O índice de umidade, *Normalized Difference Moisture Index* – NDMI ou índice água, Water Index – NDWI é utilizado em grande parte para a obtenção de informações quanto à umidade interna das vegetações. Este índice é dado pela seguinte relação:

$$NDMI \text{ ou } NDWI = \frac{G - NIR}{G + NIR}$$

Equação (3.3)

Onde, G é referente a uma banda situada na região do comprimento de onda próxima da cor verde ($\pm 490 - 580$ nm) e NIR, uma banda situada no comprimento de onda do infravermelho próximo ($\pm 760 - 1000$ nm). Segundo Jackson et al. (2004), observou-se que o NDVI saturava ao verificar mudanças na biomassa e nos estresses de umidade das plantas. No entanto, o NDWI representava melhor as mudanças no conteúdo de umidade das vegetações.

Além desses três índices que são os amplamente utilizados, tem-se diversos outros índices que também apresentam características específicas a depender da necessidade, os quais serão apresentados nos próximos subtópicos.

3.1.3.2 Índice de Vegetação Perpendicular (PVI)

Segundo Richardson e Wiegand (1977), a distância perpendicular até a “linha do solo” é usada como um indicador do desenvolvimento das plantas. A “linha do solo”, que é um índice bi-dimensional à semelhança do índice *brightness* de Kauth-Thomas, foi estimada por regressão linear. O PVI é definido a partir de dados de sensores multiespectrais da banda 4 – *Multispectral Scanner Sensor (MSS)*:

$$PVI = \sqrt{(0,355MSS4 - 0,149MSS2)^2 + (0,355MSS2 - 0,852MSS4)^2}$$

Equação (3.4)

3.1.3.3 Índice Conteúdo de Água Foliar (LWCI)

De acordo com Jensen e Epiphanyo (2011), o Índice Conteúdo de Água Foliar, *Leaf Water Content Index* – LWCI foi desenvolvido por Hunt et al (1987). O intuito desse índice é estimar os estresses de umidade foliar. Ele é dado pela equação a seguir:

$$LWCI = \frac{-\text{Log}[1 - (NIR_{TM4ft} - MidIR_{TM5})]}{-\text{Log}[1 - (NIR_{TM4ft} - MidIR_{TM5ft})]}$$

Equação (3.5)

Onde ft significa *fully turgid*, ou seja, o ponto de máximo conteúdo relativo de água expresso em reflectância pelas bandas em questão. As bandas TM4 e TM5 são referentes às bandas 4 e 5 do sensoriamento *Thematic Mapper* do Landsat. E, o conteúdo de umidade relativa, *relative water content* – RWC é dado por:

$$RWC = \frac{[\text{Peso no campo} - \text{peso após a secagem em estufa}]}{[\text{Peso túrgido} - \text{peso após a secagem em estufa}]} \times 100$$

Equação (3.6)

3.1.3.4 Índice de Vegetação Ajustado ao Solo (SAVI)

O Índice de Vegetação Ajustado ao Solo, *Soil-Adjusted Vegetation Index* – SAVI foi proposto por Huete (1987) em contraponto ao índice NDVI. O SAVI apresenta um melhor desempenho para áreas com pouca cobertura vegetal, ou seja, solo exposto. Além disso, ele apresenta uma sensibilidade à variação dos tipos de solos. Sua formulação é dada por:

$$SAVI = \frac{NIR - RED}{NIR + RED} (1 + L)$$

A primeira parte da equação é idêntica à do índice NDVI, o que a diferencia é o termo $(1 + L)$, onde L é uma constante determinada empiricamente com a finalidade de minimizar a sensibilidade do índice de vegetação às variações de reflectância dos tipos de solo. Normalmente, o valor de L é próximo de 0,5. Portanto, o intervalo dos valores de SAVI é o mesmo do NDVI (-1 a +1).

3.1.3.5 Índice de Vegetação Resistente à Atmosfera (ARVI)

O Índice de Vegetação Resistente à Atmosfera, *Atmospherically Resistant Vegetation Index* – ARVI é a construção do SAVI de forma a diminuir-se a sensibilidade dos efeitos atmosféricos devido à normalização da radiância no azul, vermelho e infravermelho. O ARVI é dado, então pela equação:

$$ARVI = \frac{\rho_{*nir} - \rho_{*rb}}{\rho_{*nir} + \rho_{*rb}}$$

Onde, $\rho_{*rb} = \rho_{*red} - \gamma(\rho_{*blue} - \rho_{*red})$

O termo ρ^* refere-se a correção necessária para o espalhamento molecular e para a absorção por ozônio nos dados de sensoriamento remoto no azul, vermelho e no infravermelho. Para minimizar os efeitos atmosféricos, normalmente atribui-se ao gama (γ) valor igual a 1,0. Diferentes valores de gama podem ser atribuídos a depender das áreas de estudo – áreas vegetadas continentais, desérticas, marítimas, etc. (KAUFMAN e TANRÉ, 1992).

3.1.3.6 Índice de Vegetação Resistente à Atmosfera e aos Solos (SARVI)

O Índice de Vegetação Resistente à Atmosfera e aos Solos, *Soil and Atmospherically Resistant Vegetation Index* – SARVI corrige tanto os ruídos devidos ao solo quanto à atmosfera. Este índice foi composto por Huete e Liu (1994), que integraram o fator L do índice SAVI e a normalização da banda azul do índice ARVI, gerando-se então o índice SARVI, da mesma forma como o MSARVI:

$$SARVI = \frac{\rho_{*nir} - \rho_{*rb}}{\rho_{*nir} + \rho_{*rb} + L}$$

$$MSARVI = \frac{2\rho_{*nir} + 1 - \sqrt{[(2\rho_{*nir} + 1)^2 - \gamma(\rho_{*nir} - \rho_{*rb})]}}{2}$$

Equação (3.10)

Segundo Jensen e Epiphanyo (2011), os índices de vegetação foram melhorados (SAVI, ARVI, SARVI, MSARVI) pelos autores Huete e Liu (1994), que concluíram o seguinte:

- Se foi feita uma correção atmosférica total, então ainda deve haver ‘ruídos de solos’, e as melhores equações a serem usadas serão as dos índices SAVI e MSARVI, enquanto os usos de NDVI e de ARVI seriam os piores.
- Se foi feita uma correção atmosférica parcial para mover os componentes *Rayleigh* – dispersão eletromagnética por partículas muito menores que o comprimento de onda dos fótons dispersados – e ozônio, então as melhores equações a serem usadas serão as dos índices SARVI e MSARVI, enquanto os usos de NDVI e de ARVI seriam os piores.
- Se não houve correção atmosférica alguma (ou seja, não houve a correção para *Rayleigh*, ozônio ou aerossóis), o índice SARVI torna-se levemente melhor, porém ainda haveria ruído total em menor grau. O NDVI e o ARVI apresentariam o maior ruído e erro.

3.1.3.7 Índice de Vegetação Livre de Aerossol (AFRI)

O Índice de Vegetação Livre de Aerossol, *Aerosol Free Vegetation Index* – AFRI foi observado por Karnieli et al. (2001). Constataram que as bandas centradas em 1,6 e 2,1 μm são altamente correlacionadas com as bandas espectrais do visível centradas na composição RGB; azul (0,469 μm), verde (0,555 μm) e vermelho (0,645 μm). Essa correlação ocorre sob condições de céu claro e, portanto, a partir dela desenvolveu-se dois índices AFRI:

$$AFRI_{1,6 \mu\text{m}} = \frac{\rho_{nir} - 0,66\rho_{1,6\mu\text{m}}}{\rho_{nir} + 0,66\rho_{1,6\mu\text{m}}}$$

Equação (3.11)

$$AFRI_{2,1\mu m} = \frac{\rho_{nir} - 0,5\rho_{2,1\mu m}}{\rho_{nir} + 0,5\rho_{2,1\mu m}}$$

Equação (3.12)

Os AFRI, portanto, apresentam-se bastante úteis em aplicações onde há presença de fumaça, poluição aérea (gases de efeito estufa antrópicos) e plumas vulcânicas. O NDVI em tais condições apresentaria um retorno de imagem de qualidade inferior ao AFRI. Esse índice pode ser aplicado utilizando-se qualquer sensor que tenha banda centrada em 1,6 e 2,1 μm (TM e ETM+ Landsat, Sentinel-2, MODIS, ASTER, JERS-OPS, SPOT-4, IRS-1 C/D). Contudo, de acordo com Kaufman et al. (2000), partículas de tamanho próximo ao comprimento de onda de 2,1 μm , que não são transparentes, pode gerar um resultado não-satisfatório.

3.1.3.8 Índice de Vegetação Realçado (EVI)

O Índice de Vegetação Realçado, *Enhanced Vegetation Index* – EVI foi desenvolvido pelo MODIS *Land Discipline Group* para uso com dados de entrada do sensor MODIS:

$$EVI = G \frac{\rho_{*nir} - \rho_{*red}}{\rho_{*nir} + C_1\rho_{*red} + C_2\rho_{*blue} + L} (1 + L)$$

Equação (3.13)

Os coeficientes C1, C2 e L são empiricamente determinados e assumem valores de 6,0; 7,5; e 1,0, respectivamente. G refere-se a um fator de ganho ajustado de 2,5. L é um fator de ajuste para solos, enquanto que C1 e C2 referem-se ao uso da banda azul para correção da banda vermelha quanto ao espalhamento atmosférico por aerossóis. Segundo Huete et al. (1997), este índice apresenta melhor desempenho do monitoramento da vegetação para regiões de alta biomassa, em que reduz-se a influência do sinal advinda abaixo da cobertura vegetal.

3.1.3.9 Índice de Vegetação Triangular (TVI)

O Índice de Vegetação Triangular, *Triangular Vegetation Index* – TVI foi desenvolvido por Broge e Leblanc (2000). Este índice descreve a diferença relativa entre as reflectâncias no vermelho e no infravermelho próximo em conjunto com a reflectância no verde, ou seja a energia radiativa absorvida. Ele é calculado como a área do triângulo definido pelo pico do verde, pelo mínimo na região de absorção de clorofila e pelo ombro do infravermelho próximo, quando se considera a curva e resposta espectral típica da

vegetação. Contudo, tanto a absorção pela clorofila gera uma redução na região do vermelho, quanto a abundância de tecido foliar gera aumento na reflectância na região do infravermelho. E, a formulação deste índice com coordenadas no espaço espectral é dada por:

$$TVI = 0,5 \left(120(\rho_{nir} - \rho_{green}) \right) - 200(\rho_{red} - \rho_{green})$$

Equação (3.14)

3.1.3.10 Razão Simples Reduzida (RSR)

O índice Razão Simples Reduzida, *Simple Reduced Ratio* – RSR é um resultado da modificação do algoritmo do Razão Simples original por Chen et al. (2002), também nomeado de RVI (vide tópico 3.2.1) de acordo com Meneses e Almeida (2012). Este índice modificado inclui informação da banda SWIR disponível no sensor *Vegetation* do satélite SPOT. Eles usaram essa razão reduzida para mapear o índice de área foliar (IAF) do Canadá. Contudo, o RSR é dado pela fórmula:

$$RSR = \frac{\rho_{nir}}{\rho_{red}} \left(1 - \frac{\rho_{swir} - \rho_{swirmin}}{\rho_{swirmax} + \rho_{swirmin}} \right)$$

Equação (3.15)

Onde $\rho_{swirmin}$ e $\rho_{swirmax}$ são os valores mínimo e máximo de reflectância SWIR que equivalem a 1% do mínimo e do máximo, no histograma da reflectância SWIR da imagem em estudo. O índice RSR apresenta maiores vantagens em relação ao Razão Simples original nos seguintes aspectos:

- A diferença entre os tipos de cobertura é muito reduzida, a precisão para recuperação de IAF para tipos diversos tipos de cobertura pode ser melhorada ou um único algoritmo IAF pode ser desenvolvido sem recorrer a uma cobertura terrestre co-registrada
- A influência do substrato (vegetação rasteira, cobertura de musgo, liteira e solo) é suprimida usando-se RSR, já que a banda SWIR é mais sensível à quantidade de vegetação que contém água líquida no substrato. (CHEN et al., 2002).

3.1.3.11 Índice de Reflectância para Absorção pela Clorofila (CARI); Índice de Reflectância para Absorção pela Clorofila Modificado

(TCARI); Índice Otimizado de Vegetação Ajustado a Solos (OSAVI); Razão TCARI/OSAVI

Kim et al. (1994) desenvolveram o Índice de Reflectância para Absorção pela Clorofila, *Chlorophyll Absorption in Reflectance Index* – CARI, que foi modificado, em seguida, para o Índice de Reflectância para Absorção pela Clorofila Modificado, *Transformed Absorption in Reflectance Index* – TCARI que é dado pela formulação a seguir:

$$TCARI = 3[(\rho_{700} - \rho_{670}) - 0,2(\rho_{700} - \rho_{550})\left(\frac{\rho_{700}}{\rho_{670}}\right)]$$

Equação (3.16)

Os termos ρ_{550} e ρ_{700} referem-se aos comprimentos de onda 550 e 700 nm que correspondem ao mínimo de absorção pelos pigmentos fotossintéticos. E, o termo ρ_{670} refere-se à banda de absorção máxima de clorofila a, no comprimento de onda 670 nm. Escolhe-se o comprimento de 700 nm, pois é a região limite onde a reflectância emitida pela vegetação é dominada pela absorção dos pigmentos, ou seja, onde as características estruturais da vegetação possuem maior influência na reflectância.

Contudo, o índice TCARI é bem sensível quando a vegetação demonstra baixo IAF. Dessa forma, Daughtry et al. (2000) realizaram a combinação dos índices TCARI com um índice de vegetação com linha de solo, semelhante ao Índice Otimizado de Vegetação Ajustado a Solos, *Optimized Soil-Adjusted Vegetation Index* – OSAVI (RONDEAUX et al., 1996):

$$OSAVI = \frac{(1 + 0,16)(\rho_{800} - \rho_{700})}{(\rho_{800} + \rho_{670} + 0,16)}$$

Equação (3.17)

Por fim, a razão entre os índices correlaciona-se altamente com o conteúdo de clorofila da vegetação, que é dada por:

$$Razão = \frac{TCARI}{OSAVI}$$

Equação (3.18)

3.1.3.12 Índice Resistente à Atmosfera no Visível (VARI)

O Índice Resistente à Atmosfera no Visível, *Visible Atmospherically Resistant Index* – VARI foi desenvolvido tendo como base o Índice de Vegetação Resistente à Atmosfera (ARVI) e, com o intuito de se evitar os efeitos da atmosfera no imageamento. Segundo Rundquist (2002), informações sobre a fração de vegetação é muito procurada por administradores de recursos naturais. De acordo com Gitelson et al. (2002), sua formulação é dada por:

$$VARI_{green} = \frac{\rho_{green} - \rho_{red}}{\rho_{green} + \rho_{red} - \rho_{blue}}$$

Equação (3.19)

Este índice apresentou-se muito favorável às medições das frações de vegetação, ou seja, foi pouco sensível aos efeitos atmosféricos e, sua estimativa apresentou um erro menor que 10% considerando-se medições em diversas espessuras.

3.1.3.13 Índice por Diferença Normalizada para Áreas Construídas (NDBI)

O Índice por Diferença Normalizada para Áreas Construídas, *Normalized Difference Built-up Index* – NDBI é de extrema importância quando deseja-se estimar e monitorar a distribuição espacial urbana, ou seja, áreas construídas (urbanas e peri-urbanas). Com esses dados, previsões acerca dos escoamentos de bacias hidrográficas, escoamentos superficiais, dentre outras aplicações no planejamento urbano podem ser realizadas. Segundo Zha et al. (2003) este índice pode ser calculado a partir do NDVI, pela fórmula:

$$NDBI = B_u - NDVI$$

Equação (3.20)

Em que B_u é dado por:

$$B_u = \frac{NIR - SWIR}{NIR + SWIR}$$

Equação (3.21)

A partir dessas equações obtém-se uma imagem, que apresenta somente valores positivos e, contém somente pixels de áreas construídas e estéreis. As outras classes

apresentam valores zero ou -254. O autor notou que esse índice apresentou uma precisão de 92% em seus resultados.

3.1.3.14 Novo Índice de Vegetação (NVI)

O Novo Índice de Vegetação, *New Vegetation Index* – NVI foi desenvolvido a fim de se aprimorar o monitoramento da biomassa do NDVI, contudo as bandas no infravermelho próximo variam entre 780 e 2500 nm (LIMA et al., 2009), região onde são incluídas bandas de absorção pelo vapor d'água. Portanto, Gupta et al. (2001) excluíram essas bandas de absorção do vapor d'água e criaram o NVI que é dado por:

$$NVI = \frac{\rho_{777} + \rho_{747}}{\rho_{673}}$$

Equação (3.22)

Em que, ρ_{777} , ρ_{747} e ρ_{673} são as reflectâncias centradas em 777, 747 e 673 nm, respectivamente, com larguras de bandas entre 3 e 10 nm utilizando dados hiperespectrais.

3.1.3.15 Determinação da Posição da Borda Vermelha (REP)

A Determinação da Posição da Borda Vermelha, *Red-edge Position Determination* – REP foi inicialmente descrita por Collins (1978) e, de acordo com Schlerf e Atzberger (2001) é, talvez, uma das determinações mais estudadas na curva espectral da vegetação. A denominação borda vermelha é provocada pela forte absorção da clorofila e o espalhamento interno da folha na região entre 680 e 800 nm. Contudo, a REP pode ser utilizada como um indicador sensível do estresse da vegetação.

Clevers (1994) propôs um método linear utilizando-se quatro bandas hiperespectrais, o que resultou na seguinte equação:

$$REP = 700 + 40 \left(\frac{\rho_{red\ edge} - \rho_{700nm}}{\rho_{740nm} - \rho_{700nm}} \right)$$

Equação (3.23)

Em que, $\rho_{red\ edge}$ é dado por:

$$\rho_{red\ edge} = \frac{\rho_{670nm} + \rho_{780nm}}{2}$$

Equação (3.24)

3.1.4 Os Satélites Landsat e Sentinel

O programa de imagens Landsat é de origem Norte Americana e teve seu lançamento na segunda metade da década de 60, a partir de um projeto desenvolvido pela Administração Nacional de Aeronáutica e Espaço (NASA), sendo dedicado exclusivamente à observação dos recursos naturais terrestres. Esse programa foi inicialmente denominado ERTS (*Earth Resources Technology Satellite*) e, posteriormente, em 1975 passou a se denominar LANDSAT. O LANDSAT-1 foi lançado em 1972, também era denominado de ERTS-1. Este foi desenvolvido para atuar de forma pioneira em pesquisas de recursos naturais. Além disso, foi o primeiro satélite de sensoriamento remoto no mundo, equipado com duas câmeras RBV e MSS. Ele ficou em atividade por cinco anos, o que resultou mais de 300.000 imagens de séries da cobertura de todo o planeta Terra.

Desde o ano de seu lançamento, foram lançados 8 satélites da série, todos utilizam o princípio de imagem multiespectral. No catálogo do INPE é possível encontrar imagens do *Multispectral Scanner Sensor* (MSS) com 80m de resolução espacial, para os satélites LANDSAT 1,2 e 3 (1972-1992); do sensor Thematic Mapper (TM) de 30m resolução espacial, nos satélites LANDSAT-5 (1984-2011), e o sensor LANDSAT Enhanced Thematic Mapper Plus (ETM +) de 15 a 30 m de resolução, no satélite LANDSAT-7 (desde 1999) e; do sensor OLI (Operational Terra Imager) e TIRS (Thermal Infrared Sensor) 15 a 30 metros de dados multiespectrais do LANDSAT-8 (Desde 2013). As imagens do LANDSAT-8 são ortoretificadas e todos os produtos do catálogo estão em formato GeoTIFF (INPE, 2015).

Diferentemente do programa de imagens Landsat o programa de imagens Sentinel é desenvolvido pela Agência Europeia Espacial (The European Space Agency – ESA), essas missões carregam uma gama de tecnologias, tais como instrumentos de imagem de radar e multi-espectral para monitoramento terrestre, oceânico e atmosférico:

Sentinel-1 é uma missão de imagem de radar em órbita polar, para todos os climas, dia e noite, para serviços terrestres e oceânicos. O Sentinel-1A foi lançado em 3 de abril de 2014 e o Sentinel-1B em 25 de abril de 2016. Ambos foram colocados em órbita em um foguete Soyuz do Espaçoporto da Europa, na Guiana Francesa.

O Sentinel-2 é uma missão de imagem de alta resolução multiespectral polar em órbita polar para o monitoramento da terra para fornecer, por exemplo, imagens da

vegetação, cobertura do solo e da água, vias navegáveis interiores e áreas costeiras. O Sentinel-2 também pode fornecer informações para serviços de emergência. O Sentinel-2A foi lançado em 23 de junho de 2015 e o Sentinel-2B seguido em 7 de março de 2017.

O Sentinel-3 é uma missão de vários instrumentos para medir a topografia da superfície do mar, a temperatura da superfície do mar e da terra, a cor do oceano e a cor da terra com precisão e confiabilidade de ponta. A missão apoiará os sistemas de previsão do oceano, assim como o monitoramento ambiental e climático. O Sentinel-3A foi lançado em 16 de fevereiro de 2016 e o Sentinel-3B se uniu ao seu gêmeo em órbita em 25 de abril de 2018.

O Sentinel-5 Precursor - também conhecido como Sentinel-5P - é o precursor do Sentinel-5 para fornecer dados oportunos sobre uma infinidade de gases residuais e aerossóis que afetam a qualidade do ar e o clima. Foi desenvolvido para reduzir as diferenças de dados entre o satélite Envisat - em particular o instrumento Sciamachy - e o lançamento do Sentinel-5. O Sentinel-5P foi colocado em órbita por meio de um foguete aeroespacial do Cosmódromo de Plesetsk, no norte da Rússia, em 13 de outubro de 2017.

O Sentinel-4 é uma missão *payload* – lançada em formato foguete – dedicada ao monitoramento atmosférico que será embarcado em um satélite Meteosat de Terceira Geração-Sonda (MTG-S) em órbita geoestacionária.

Sentinel-5 também é uma missão *payload* que irá monitorar a atmosfera da órbita polar a bordo de um satélite MetOp Segunda Geração.

O Sentinel-6 transporta um altímetro de radar para medir a altura global da superfície do mar, principalmente para oceanografia operacional e para estudos climáticos. (ESA, 2018).

Na figura 3.7 é possível perceber as diferenças em termos de transmissão atmosférica e do comprimento de onda de cada banda pelos satélites Landsat 7, Landsat 8 e Sentinel-2. A partir da figura, pode-se notar que apesar do Sentinel-2 não possuir disponibilidade de obtenção de imagens na região do termal (10000 – 13000 nm), ele apresenta uma maior quantidade de subdivisões de bandas na região do visível. Contudo, a depender da necessidade e da aplicação pode-se optar pelo uso em conjunto dos dois satélites ou pelo uso individual.

Na tabela 3.1 foram levantadas algumas informações de forma comparativa entre os satélites Landsat 8 e Sentinel 2.




Figura 3.7 Comparação da Janela Espectral entre Landsat e Sentinel. (ESA, 2018)

Tabela 3.1 Comparação entre os satélites Landsat 8 e Sentinel-2 (Adaptado de ENGESAT, 2015).

		Landsat 8				Sentinel-2		
			Número e nome da banda	λ alcance (nm)			Número e nome da banda	λ central (nm)
Resolução Espacial	11 bandas	15 m Pancromático	Banda 8	500-680	13 bandas	10 m	B2 - Blue	490
							B3 - Green	560
							B4 - Red	665
							B8 - NIR	842
		30 m Multiespectral (bandas 1-7 e 9)	Banda 1	430-450		20 m	B5 - Red Edge 1	705
			Banda 2	450-510			B6 - Red Edge 2	740
			Banda 3	530-590			B7 - Red Edge 3	783
			Banda 4 (vermelho)	640-690			B8A - Red Edge 4	865

			Banda 5 (NIR)	850-880			B11 - SWIR 1	1610	
			Banda 6 (SWIR1)	1570-1650			B12 - SWIR 2	2190	
			Banda 7 (SWIR2)	2110-2290					
			Banda 9 (Cirrus)	1360-1380					
		100 m Termal (bandas 10-11)	TIRS1	10600-11190		60 m	B1 – Aerossol	443	
			TIRS2	11500-12510			B9 – Water Vapor	940	
							B10 – Cirrus	1375	

Resolução Radiométrica		16 bits por pixel			12 bits por pixel	
------------------------	--	-------------------	--	--	-------------------	--

Largura da faixa Imageada		185 km			290 km	
---------------------------	--	--------	--	--	--------	--

3.1.5 Shuttle Radar Topography Mission (SRTM)

A missão SRTM foi realizada pela National Imagery and Mapping Agency (NIMA) e pela National Aeronautics and Space Administration (NASA). Os dados de radar foram coletados no período de 11 a 22 de fevereiro de 2000 (durante 11 dias), a bordo da nave espacial Endeavour. Foram 16 órbitas diárias na Terra correspondendo a 176 órbitas durante toda a missão.

O objetivo da missão SRTM foi levantar dados digitais de todo o planeta, para a elaboração de um Modelo Digital de Elevação (MDE) das terras continentais. Os dados foram produzidos para a região do planeta posicionada entre os paralelos 56°S e 60°N.

O SRTM utiliza um método de coleta de dados conhecido como interferometria SAR. A distribuição dos dados foi feita em formato raster pelo EROS Data Center, controlado pelo United States Geological Survey (USGS) e podem ser acessados em

formato HGT, com resolução radiométrica de 16 bits. Os MDEs são organizados em tiles de 1°x1° e oferecem 30 m de resolução vertical para os Estados Unidos e 90 m de resolução vertical para as outras localidades. (EMBRAPA, 2013).

3.1.6 The Tropical Rainfall Measuring Mission (TRMM)

O TRMM é uma missão conjunta entre a NASA e a Agência de Exploração Aeroespacial do Japão (JAXA), projetada para monitorar e estudar as chuvas tropicais. Este conjunto de dados mescla algoritmicamente dados de microondas de vários satélites, incluindo SSMI, SSMIS, MHS, AMSU-B e AMSR-E, cada um calibrado entre si pelo TRMM Combined Instrument. O produto 34B2 contém uma precipitação infravermelha (mm / h) combinada, ajustada por TRMM, com malha quadrada e estimativa de erro de precipitação RMS, com uma resolução temporal de 3 horas e uma resolução espacial de 0,25 graus (NASA, 2018).

3.2 GEOPROCESSAMENTO

3.2.1 Sistema de Informações Geográficas

A partir de um SIG é possível a integração e análise de informações geográficas. Um SIG é definido, portanto, como um sistema computacional em que a principal aplicação deste é utilizada para o entendimento de fatos e fenômenos geográficos (PINA e SANTOS, 2000). Alguns dos benefícios mais comuns de um SIG são:

- Melhor armazenamento e atualização dos dados;
- Recuperação de informações de forma mais eficiente;
- Produção de informações mais precisas;
- Rapidez na análise de alternativas; e
- A vantagem de decisões mais acertadas.

A sua capacidade de reunir uma grande quantidade de dados convencionais de expressão espacial, estruturando-os e integrando-os adequadamente, torna-os ferramentas essenciais para a manipulação das informações geográficas.

3.2.2 Google Earth Engine

O *Google Earth Engine* (GEE) é considerado uma ferramenta de SIG e pode ser usada para monitoramento urbano e análise de dados geográficos e ambientais no mundo todo. Devido ao seu armazenamento de imagens na nuvem, a plataforma conta com mais

de 40 anos de imagens globais de satélite, ou seja, imagens históricas e atuais de todo o planeta Terra. Existem diversas aplicações de uso por meio da plataforma, alguns exemplos são: detecção de desmatamento, classificação da cobertura da terra e das alterações na cobertura da terra, estimativa de biomassa florestal e de carbono, além do mapeamento de áreas sem estradas do mundo.

Contudo, uma grande vantagem dessa plataforma é a possibilidade de fazer todo o processamento por meio do servidor em nuvem, ou seja, não há a necessidade de se realizar processamentos fazendo-se uso da memória *ram* do computador – o que pode-se perceber elevada demanda quando se utiliza outros *softwares* pagos ou até mesmo gratuitos (GOOGLE, 2017).

3.2.3 Programas de SIG Tradicionais

Existem diversos programas disponíveis atualmente de SIG, como por exemplo, o ArcGIS, que é um *software pago*, O Quantum GIS (QGIS) e SPRING, que são programas programas livres.

O ArcGIS é um *software* SIG desenvolvido pela empresa *Environmental Systems Research Institute* (ESRI). Apresenta diversas funções: análise espacial, imageamento e sensoriamento remoto, mapeamento e visualização, SIG em tempo real, SIG 3D e base de dados própria. Para a utilização desse programa é necessário adquirir uma licença paga. A sua primeira versão foi em 27 de dezembro de 1999 e a versão mais atual é de 27 de março de 2019 (versão 10.7). Sua programação foi gravada em C++.

O QGIS é um *software* SIG livre e aberto, ou seja, foi desenvolvido de acordo com a Licença Pública Geral – GNU, um projeto oficial da *Open Source Geospatial Foundation* (OSGeo). Por ser um programa de código aberto, o usuário pode contribuir em suas modificações. Além disso, É um programa que roda em diversos sistemas operacionais, dentre eles Linux, Unix, Mac OSX, Windows e Android e suporta inúmeros formatos de vetores, rasters e bases de dados e funcionalidades. Foi lançado em 2002 e sua versão mais estável é a 2.18 (lançada em 21 de outubro de 2016). Contudo, há uma versão em fase de testes, a 3.4. Sua programação foi gravada em C++, *Python* e QT.

O SPRING é um *software* SIG desenvolvido em parceria pelo Instituto Nacional de Pesquisas Espaciais e pela Divisão de Processamento de Imagens (INPE/DPI) com financiamento do CNPq. É um sistema que apresenta funções de processamento de

imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados espaciais. É uma plataforma gratuita e pode ser instalada nos sistemas Windows, Linux e Mac. Sua primeira versão foi desenvolvida no ano de 1991. A versão atual do sistema é a 5.5.2 e sua linguagem de programação pode ser facilmente programável pelo usuário (LEGAL - Linguagem Espaço-Geográfica baseada em Álgebra).

Para o presente trabalho, utilizou-se o QGIS por ser um software gratuito e pela facilidade de seu uso.

3.3 Planejamento Urbano

3.3.1 Expansão Urbana

As cidades se desenvolvem e crescem rapidamente, entretanto na maioria das vezes de forma desordenada e descontrolada. Japiassú e Lins (2014) definem expansão urbana como um processo referente à dinâmica da cidade justificando ou resultando em seu crescimento. Além disso, dividem o processo de expansão urbana em crescimento territorial urbano intensivo e extensivo. Ambas as divisões levam em conta o uso e ocupação do solo, uma de forma intensiva e outra em extensão do tecido urbano.

Para avaliar esse processo de expansão urbana muitos autores utilizam o dado demográfico (GROSTEIN, 2001; DE BARCELLOS, 2004; BRITO e SOUZA, 2005; COSTA, 2005; COPQUE, et al, 2011), ou pelo crescimento territorial propriamente dito, o crescimento físico. Contudo, ambos os fatores estão relacionados. (SANTORO, 2012).

A fim de orientar, controlar e categorizar as áreas de crescimento e expansão de uma cidade, alguns instrumentos de lei são previstos. Como o Plano Diretor de Ordenamento Territorial (PDOT), a Lei Complementar nº 948/2019 de Uso e Ocupação do Solo (LUOS) e o Zoneamento Ecológico-Econômico do Distrito Federal (ZEE – DF). Para o presente projeto utilizou-se o ZEE – DF considerando-se a sua importância para a análise ambiental.

3.3.2 Zoneamento Ecológico-Econômico do Distrito Federal (ZEE-DF)

De acordo com o Decreto Federal nº 4.297/2002 artigo 1º o Zoneamento Ecológico-Econômico é um instrumento previsto pela Política Nacional do Meio Ambiente (BRASIL, 2002). O Zoneamento Ecológico-Econômico do Distrito Federal (ZEE-DF) está previsto na Lei Orgânica do Distrito Federal de 1993. Seu principal objetivo é subsidiar as ações de

planejamento do Governo do Distrito Federal (GDF), a fim de direcionar a gestão e o uso do território, essencialmente no que diz respeito a ocupações desordenadas e indevidas.

O ZEE normatiza e institui a definição dos objetivos e princípios, estes são previstos nos artigos 4º e 5º da Lei Distrital 6269/2019:

Art. 4º O ZEE-DF tem por objetivo geral a promoção da sustentabilidade no Distrito Federal nas dimensões social, econômica, ambiental e político-institucional, por meio da compatibilização do desenvolvimento socioeconômico inclusivo com os riscos ecológicos e os serviços ecossistêmicos, em favor das presentes e futuras gerações.

Art. 5º São objetivos específicos do ZEE-DF:

I - diversificar a matriz produtiva com inclusão socioeconômica e geração de emprego e renda, de modo compatível com a capacidade de suporte ambiental;

II - estimular a economia da conservação, como estratégia para manutenção e recuperação da vegetação nativa do Cerrado;

III - estimular atividades produtivas, em especial a industrial, pouco intensivas no uso da água e recursos naturais, e de baixa emissão de poluentes;

IV - promover a distribuição da geração de emprego e renda no território;

V - incorporar a avaliação dos riscos ecológicos nos instrumentos formais de planejamento e gestão pública e privada para garantia da integridade dos ecossistemas;

VI - orientar os agentes públicos e privados quanto à observância da capacidade de suporte ambiental, na elaboração e execução das políticas públicas;

VII - orientar e fundamentar a elaboração e execução dos instrumentos públicos e privados de planejamento e gestão territorial visando à integração com as políticas de meio ambiente, de recursos hídricos, de desenvolvimento econômico e social, de habitação, de mobilidade, de saneamento e as demais políticas públicas;

VIII - preservar, proteger, promover, manter e recuperar os patrimônios ecológico, paisagístico, histórico, arquitetônico, artístico e cultural de Brasília como capital federal e Patrimônio Cultural da Humanidade e Reserva da Biosfera do Cerrado;

IX - preservar e proteger as águas no território do Distrito Federal, promovendo ações de gestão e manejo que visem estabilizar ou elevar os níveis de água nos aquíferos e melhorar a qualidade e a quantidade de águas superficiais, reconhecendo e valorizando suas diversas dimensões, seus usos múltiplos e as distintas visões e valores a elas associados na condição de berço das águas de 3 bacias hidrográficas brasileiras;

X - promover a integração do Distrito Federal com a Região Integrada de Desenvolvimento do Distrito Federal e Entorno - Ride/DF, especialmente junto aos municípios limítrofes.

A figura 3.8 mostra as macrorregiões do Zoneamento e, a partir delas têm-se as distinções em sub-regiões ou subzonas como definidas na própria Lei Distrital 6269/2019.

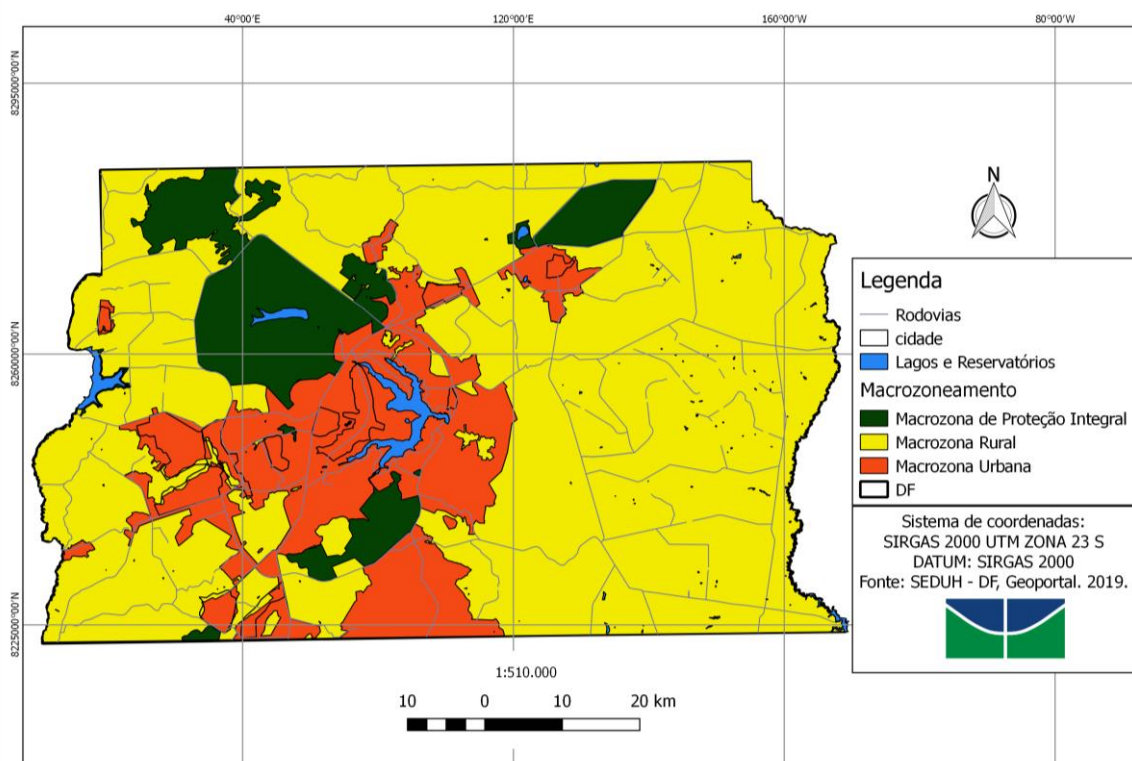


Figura 3.8 Mapa do Macrozoneamento do Distrito Federal, do ZEE – DF.

4. MATERIAIS E MÉTODOS

4.1 ÁREA DE ESTUDO

A Área de estudo para o presente projeto é a delimitação geográfica do DF todo, localizado na região Centro-Oeste do Brasil, conforme ilustrado na figura 4.1. A região é conhecida por ser cabeceira de afluentes de três dos maiores rios brasileiros – o Rio Maranhão (afluente do Rio Tocantins), o Rio Preto (afluente do Rio São Francisco) e os rios São Bartolomeu e Descoberto (tributários do Rio Paraná). O DF está localizado a 15°47' de latitude sul e a 47°56' de longitude oeste, ocupa uma área de 5.760,783 km² e atualmente tem uma população de 3,013 milhões (IBGE, 2017). Está a aproximadamente 1.000 metros acima do nível do mar e apresenta um relevo em sua maioria plano. O ponto mais alto é o Pico do Roncador, com 1.341 metros, localizado na Serra do Sobradinho. O Cerrado é o Bioma presente na região, que conta com 11.627 espécies de plantas, além de diversas outras espécies animais. Apresenta clima tropical, com temperatura média de 22 °C e variações que vão de 13 °C a 28 °C. A região é também conhecida pelos longos períodos de seca, podendo durar até 5 meses. Contudo, o DF conta com 31 Regiões

Administrativas (RA's) oficialmente constituídas como dependentes do Governo do Distrito Federal (GDF, 2017).

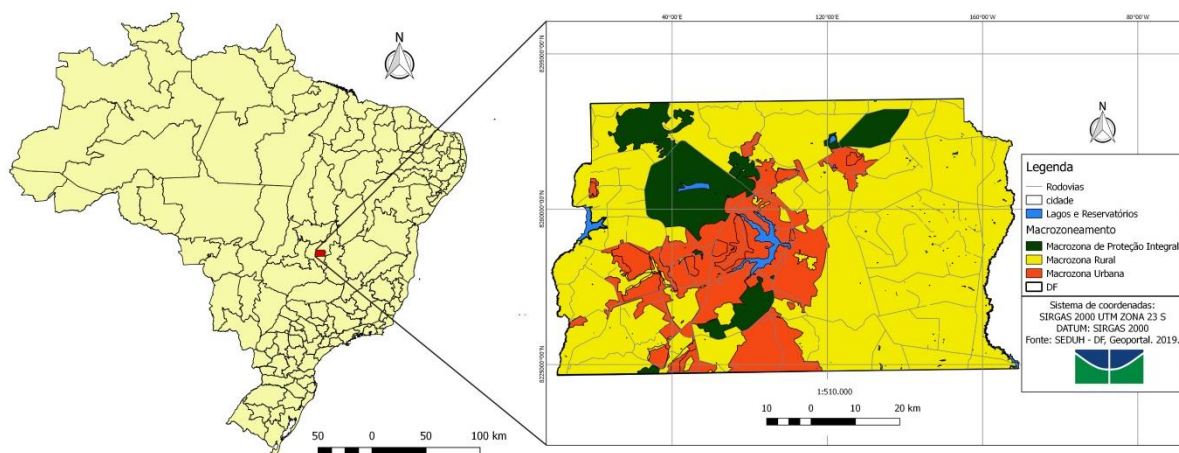


Figura 4.1 Mapa de Localização da Área de Estudo – DF.

4.2 MATERIAIS

4.2.1 Equipamento

Notebook Dell Inspiron I7, 8 GB de memória RAM, placa de vídeo dedicada Nvidia GeForce 1 GB de memória.

4.2.2 Banco de Dados

O banco de dados utilizado foi acessado via GEE. Para o processamento realizado com o NDVI utilizou-se a mesma coleção de imagens a fim de evitar qualquer tipo de viés na comparação dos resultados entre o GEE e o QGIS.

O banco de dados de imagens a seguir foi utilizado para a geração dos resultados no GEE:

- Satélite *MODIS Surface Reflectance* fornecido e alimentado pela Nasa, com tempo de revisita de 1 dia. A imagem promovida por ele possui uma resolução espacial de 1000 m. Possui disponibilidade de imagens desde 24 de fevereiro de 2000. Data da imagem utilizada: 10/10/2012.
- Modelo digital de elevação da missão SRTM desenvolvido pela NASA (USGS) com resolução espacial de 30 m.
- *USGS Landsat 7 Collection 1 Tier 1 and Real-Time data TOA Reflectance*: coleção do Landsat ortoretificada, alimentada constantemente pela Nasa e

com a maior quantidade de imagens disponível, com intervalo de revisita de 16 dias e resolução espacial de 30 m. Possui disponibilidade de imagens desde 1º de janeiro de 1999.

- *USGS Landsat 8 Collection 1 Tier 1 and Real-Time data TOA Reflectance*: coleção do Landsat ortoretificada, alimentada constantemente pela Nasa e com a maior quantidade de imagens disponível, com intervalo de revisita de 16 dias e resolução espacial de 30 m. Possui disponibilidade de imagens desde 11 de abril de 2013.
- *Sentinel-2 MSI: MultiSpectral Instrument, Level-2A*: coleção de imagens do Sentinel-2 coletadas pela missão Copernicus da ESA, com intervalo de revisita de 5 dias e resolução espacial de 10 m. Possui disponibilidade de imagens desde 28 de março de 2017. Período utilizado:

Para gerar o resultado de NDVI no programa QGIS, utilizou-se o seguinte banco de dados:

- *USGS Landsat 8 Collection 1 Tier 1 and Real-Time data TOA Reflectance*: coleção do Landsat ortoretificada, alimentada constantemente pela Nasa e com a maior quantidade de imagens disponível, com intervalo de revisita de 16 dias e resolução espacial de 30 m. Possui disponibilidade de imagens desde 11 de abril de 2013.

4.3 METODOLOGIA

A partir da revisão bibliográfica de uma série de índices e do uso da ferramenta GEE verificou-se a potencialidade da mesma, quando comparado ao QGIS. Além disso, realizou-se a identificação de áreas em que ocorreu urbanização utilizando-se os índices NDVI, NDWI, NDBI, EVI, SAVI.

O período utilizado para a análise e geração dos resultados de NDVI, EVI e SAVI foi de 01 de janeiro de 2017 a 11 de setembro de 2017.

O período utilizado para o cálculo do NDBI com as imagens do Landsat 7 foi o ano de 2000, ano de 2010 e 2019 (01/01/19 a 27/05/19). Para as imagens do Landsat 8, utilizou-se o ano de 2013 (11/04/13 a 31/12/13), 2017 (01/01/17 a 11/09/17) e 2019 (01/01/19 a 10/05/19). E para as imagens do Sentinel – 2A utilizou-se o período de (01/01/19 a 13/05/19).

Para a análise do índice de água – NDWI – utilizou-se uma coleção de imagens do Landsat 8 e foram escolhidos dois períodos: chuvoso e seco. O ano considerado foi o de 2018, levando-se em conta as imagens disponíveis.

Para a escolha dos meses utilizou-se a base do TRMM. A partir dela foi possível verificar, no ano escolhido, o mês de menor e maior índice pluviométrico considerando-se um período de um ano. A unidade de medida da precipitação é em mm/hora e, o *stretch* utilizado foi por desvio padrão (σ) em relação à média mensal.

Os meses de menor precipitação para o ano de 2018 foram junho e julho em que foram registrados 0,00 mm/h de chuva. O mês de máxima precipitação registrado no ano de 2018 foi o mês de novembro, cuja mínima foi de 0,352 mm/h e a máxima foi de 0,391 mm/h. O código desenvolvido para os cálculos do TRMM pode ser consultado no apêndice J.

O NDWI para o período de seca calculado levou em conta o mês de julho e para o período chuvoso utilizou-se o mês de dezembro do mesmo ano, pois o mês de novembro não apresentou imagens coletadas pelo satélite em questão. Verificou-se também o mês anterior a novembro (outubro), contudo também não retornou imagens para o DF. Portanto, na sequência temporal e em termos de escala de chuva, escolheu-se o mês de dezembro, que apresentou uma mínima de precipitação de 0,219 mm/h e a máxima de 0,294 mm/h. Na figura a seguir pode-se verificar o NDWI gerado para o mês de julho e dezembro de 2018.

Além da própria ferramenta do GEE, ainda utilizou-se o Google Drive como plataforma de armazenamento em nuvem. No GEE, existe a possibilidade de compartilhamento do código com outra pessoa dentro da própria plataforma. Contudo, o código pode ser editado por mais de uma pessoa em tempo real, possibilitando a rápida troca de informações e ajustes. De fato isso é uma vantagem em relação ao SIG tradicional.

4.3.1 Procedimentos Gerais de um SIG Tradicional

A partir do conhecimento sobre o funcionamento do GEE, realizou-se a comparação entre uma ferramenta de SIG tradicional (QGIS) e a ferramenta em questão. Para tanto, alguns passos gerais foram seguidos para que pudessem ser avaliados os possíveis ganhos em quantidade e qualidade no processamento de imagens.

No processamento tradicional, para ter uma imagem preparada para qualquer procedimento são necessários alguns passos como os descritos a seguir:

1. Baixar a imagem de satélite a ser usada;
2. Importar a imagem para o SIG;
3. Pré-processamento;
4. Realce.

A partir desses procedimentos iniciais é possível realizar os outros procedimentos que desejar para análise da imagem e geração de resultados, como exemplo, composição RGB, operações aritméticas entre Bandas, Segmentação da imagem, dentre outras. A figura 4.2 demonstra em forma de diagrama os procedimentos iniciais e suas possíveis ramificações a partir deles.

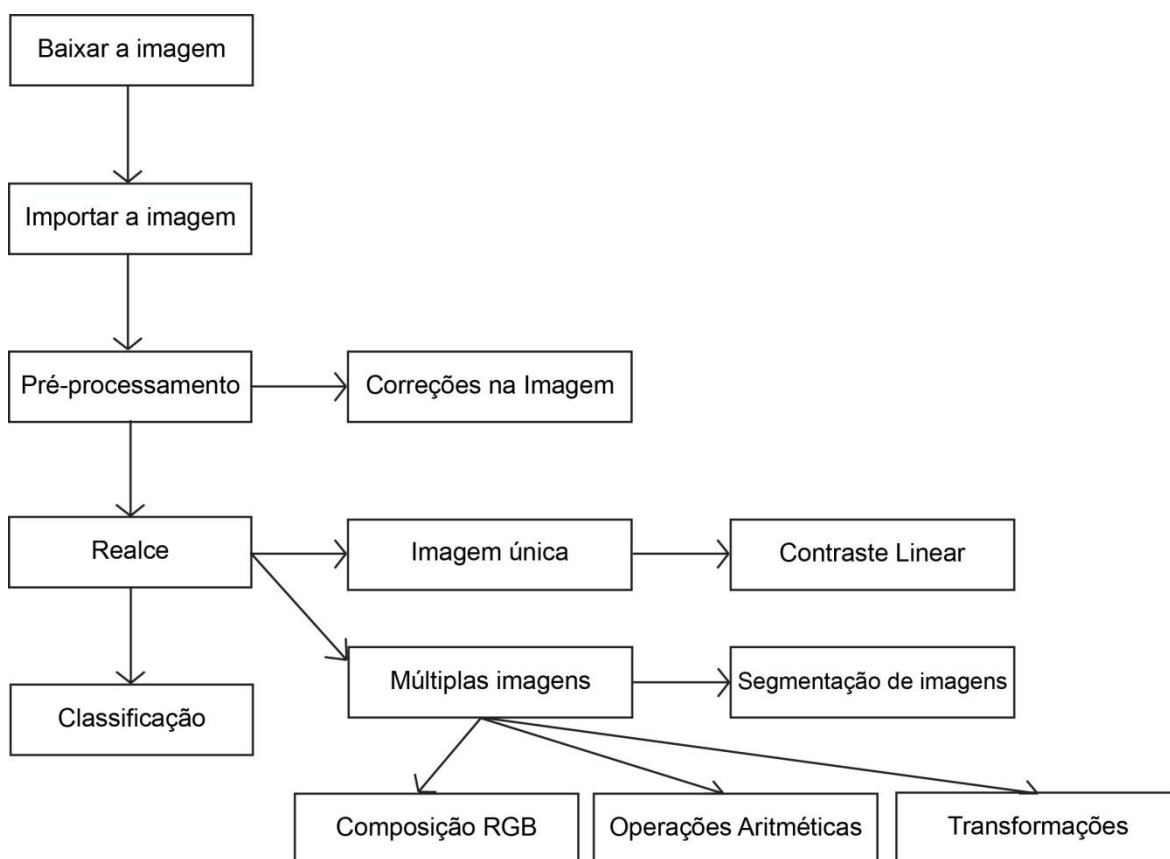


Figura 4.2 Passos para um processamento em um SIG tradicional.

4.3.2 Aplicação do Google Earth Engine (GEE)

A plataforma GEE é um sistema que possui a capacidade de realizar processamentos de imagens de satélite a partir de seu próprio servidor na internet, ou seja, não há a necessidade de ter um computador robusto em termos de processamento. E,

conforme mencionado no tópico 3.2.2, o *software* é capaz de realizar qualquer processamento que um SIG tradicional faz.

Quando comparado com o processamento tradicional de uma imagem, no GEE não há a necessidade de baixar a imagem de satélite, por exemplo. É necessário, apenas o local e a operação que se pretende realizar. O procedimento para o uso das coleções de imagens disponíveis pelo Google será explicado no tópico 4.3.3.

Dentro da própria plataforma já existem diversos códigos pré-programados e que podem ser aplicados para outras áreas. Contudo, existem alguns passos básicos que o usuário precisa seguir para começar a utilizar a plataforma, estes são:

1. Ter uma conta Google
2. Vincular sua conta com a plataforma GEE

Para vincular a conta Google com a plataforma do GEE basta acessar a página de código (<https://code.earthengine.google.com>) e clicar em *sign in*. Em seguida, colocar seu e-mail e senha do Google para vincular. Após vincular a conta, a tela inicial será conforme a figura 4.3.

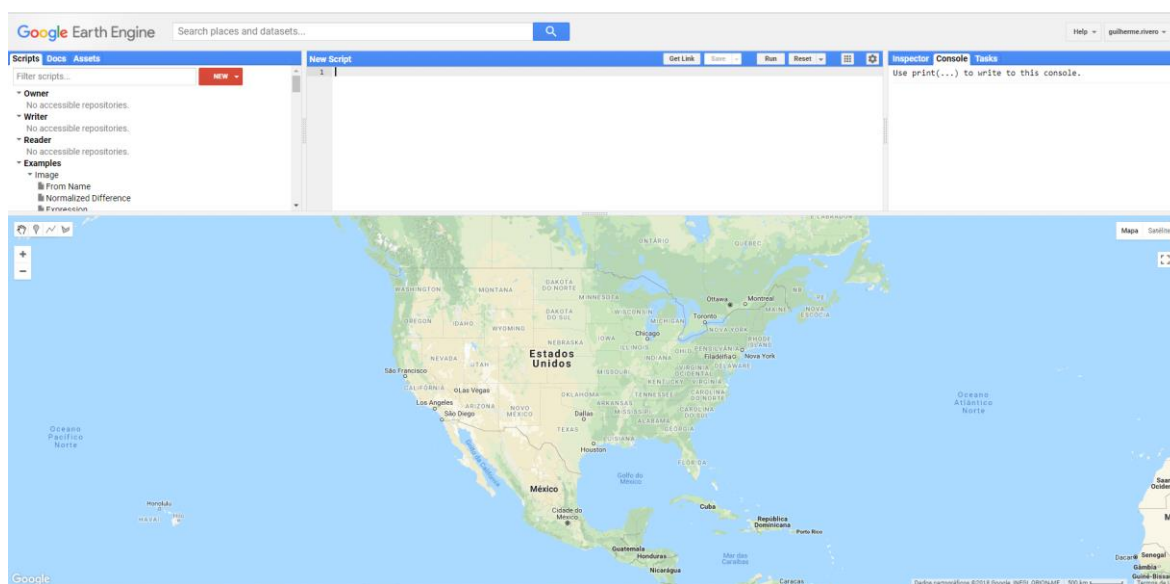


Figura 4.3 Página Inicial do Google Earth Engine.

Os procedimentos descritos a seguir possuem a base a partir da página Google Earth Solidário (https://www.google.com/intl/pt-BR_br/earth/outreach) e de tutoriais encontrados no *Youtube* (SADECK, 2017). Por se tratar de uma ferramenta muito recente

existem poucos artigos e/ou livros que tratam da temática por meio de uma abordagem mais técnica e direcionada ao uso propriamente dito do GEE.

Qualquer processamento que se pretende realizar, será feito a partir da janela de *script* (janela do meio), que é programada na linguagem JavaScript API (do inglês *Application Programming Interface* ou Interface de Programação de Aplicativos, em português). Na janela da esquerda localizam-se os exemplos de códigos já gerados e possíveis códigos salvos do usuário. Na janela à direita encontra-se o console onde são indicados possíveis erros de código no *script*. Na figura 4.4, as principais funcionalidades e botões podem ser identificados.

A função “*run*”, por exemplo, roda o código dentro da janela de *script*. E, para ilustrar essa função, a figura 4.5 mostra o resultado do cálculo gerado para o NDVI na região do DF, utilizando-se uma imagem do satélite MODIS. O código para o NDVI é um dos códigos já pré-programados que está disponível dentro do GEE. Contudo, ele foi alterado a fim de se inserir o contorno do DF.

Para a obtenção do contorno é necessário que seja criada uma tabela fusão do Google (*Fusion Table*). Gerou-se, portanto, essa tabela a partir de um arquivo *shapefile* do IBGE. A tabela fusão pode ser gerada a partir do *Google Drive*, clicando-se com o botão direito do mouse, na opção “mais” ou “*more*” e, em seguida “*Google Fusion Table*”. O formato de arquivo para a tabela fusão precisa estar em “.kml”, para tanto é necessário importar o arquivo *shapefile* para o Google Earth para salvá-lo como “.kml”. A figura 4.6 mostra como criar a tabela fusão e fazer o carregamento do arquivo.

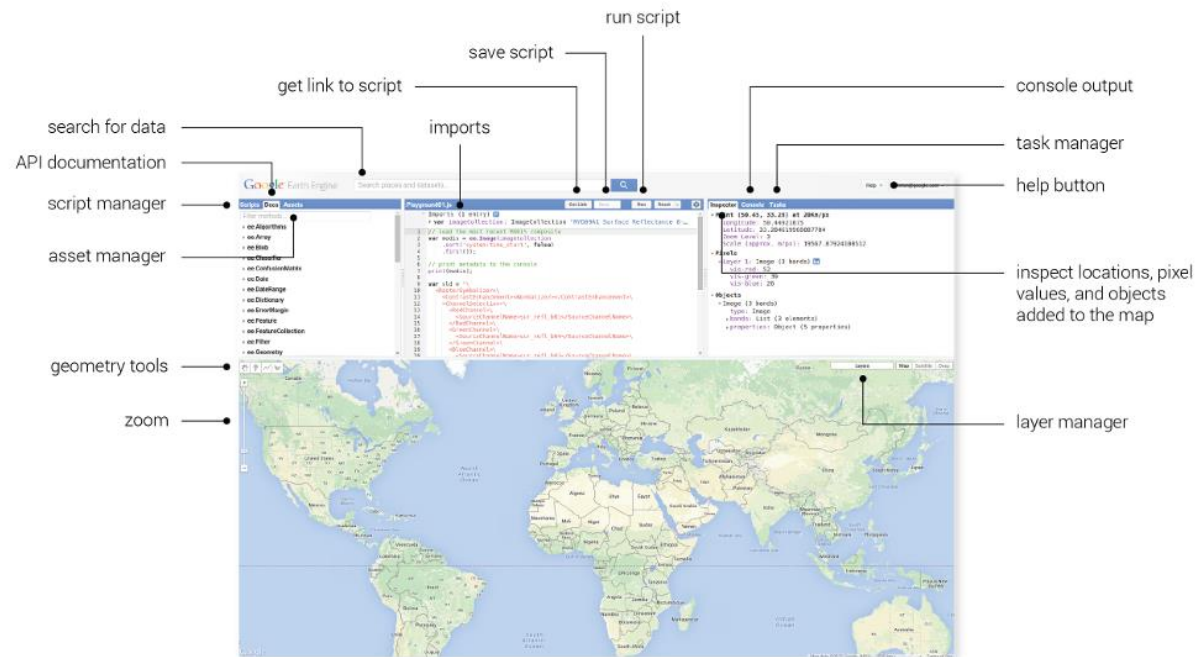


Figura 4.4 Página de *script* do GEE e suas funcionalidades (GOOGLE, 2017).

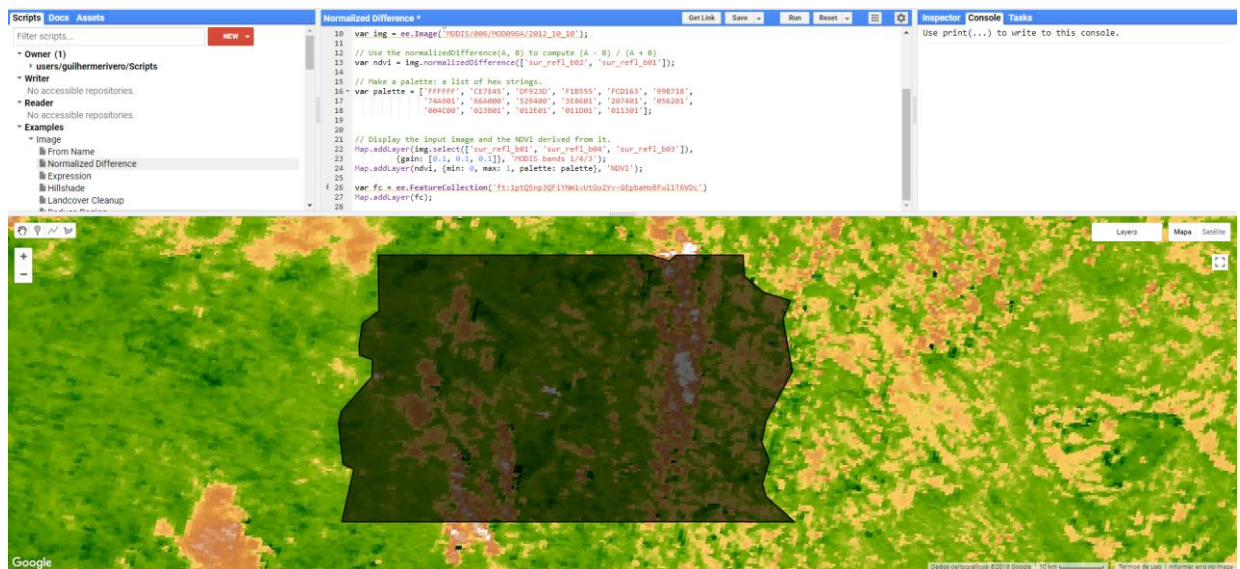


Figura 4.5 NDVI gerado a partir de imagens do satélite MODIS para a região do DF.

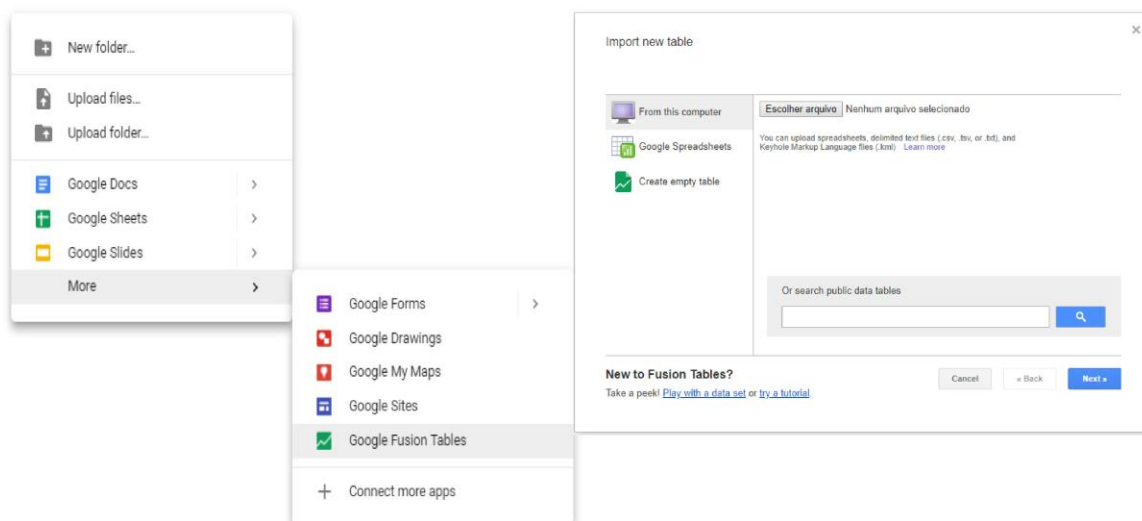


Figura 4.6 Criação da *Fusion Table* no *Google Drive*.

4.3.3 Procedimentos Gerais no GEE

Para a realização do processamento de imagens no GEE, conforme mencionado no tópico 4.3.2, não há necessidade de baixar a imagem do site de origem, basta importar a coleção a partir do próprio código. Diferentemente do SIG tradicional, os procedimentos de realce da imagem e correções de ruído – na maioria das vezes nuvens – são feitos diretamente no código. Existe a possibilidade de escolher o percentual de nuvens que se deseja na imagem com poucas linhas de código. O tópico 4.3.5 elucida como realizar a função de remoção de nuvens.

A função de realce da imagem pode ser realizada diretamente na aba de parâmetros da imagem, ilustrada na figura 4.7, em que a partir da função *stretch* pode ser aplicar os limites mínimos e máximos de correção na imagem.

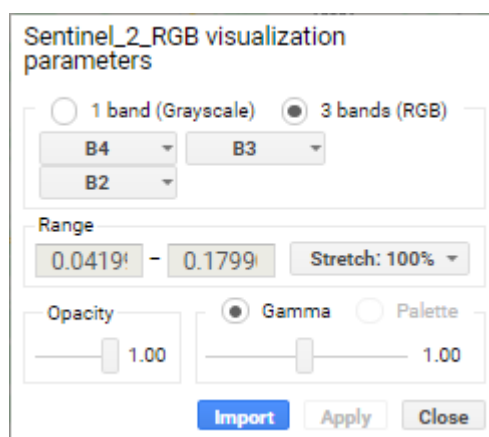


Figura 4.7 Visualização de parâmetros da imagem, Sentinel – 2A_RGB.

Na figura 4.8 é possível perceber em (A) a imagem sem realce e em (B) a imagem após o realce com *stretch*: 100% para a composição RGB de uma coleção de imagens do Sentinel – 2A.




Figura 4.8 Comparação da imagem sem realce (A) e com realce (B), imagem Sentinel – 2A.

Em seguida, pode-se realizar as operações aritméticas que desejar a partir da programação do código (página de *script*).

Em comparação com o tópico 4.3.1., em que foram levantados os procedimentos gerais de um SIG tradicional, pode-se citar praticamente os mesmos passos básicos para o GEE.

4.3.4 Principais Atalhos no GEE

A ferramenta GEE, assim como a maioria dos programas, possui diversos atalhos de comandos. Alguns deles podem ser citados, já que foram os mais utilizados durante o desenvolvimento do projeto em questão. Estes são:

- Ctrl + barra de espaço – Mostra e dá uma explicação sobre o que determinada função realiza. É uma janela de ajuda/dicas do GEE (conforme figura 4.9);
- Ctrl + Enter – Roda o código que está na janela de *script* (conforme figura 4.10);
- Alt + mouse – possibilita a alteração em duas linhas ou mais simultaneamente (conforme figura 4.11)

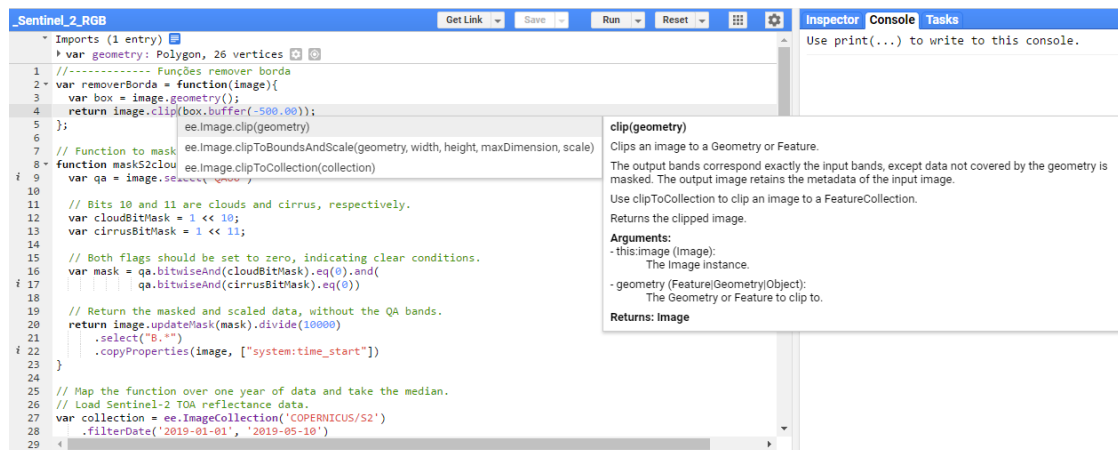


Figura 4.9 Utilização janela de ajuda GEE com o exemplo para o uso do *clip*.

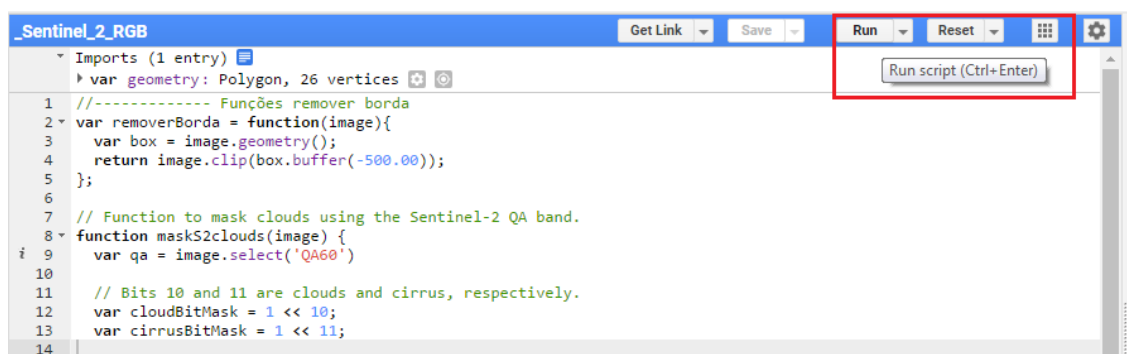


Figura 4.10 Utilização do atalho para rodar o código.

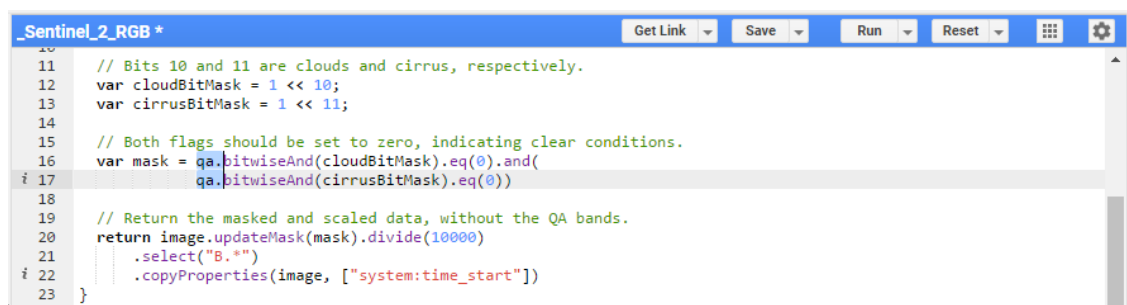


Figura 4.11 Utilização do atalho para alteração múltipla.

4.3.5 Utilização da Coleção de Imagens

A análise ou o estudo pode ser feito utilizando-se apenas uma imagem ou uma coleção de imagens. Para a importação de uma coleção de imagens cria-se uma variável e atribui-se a ela uma função de coleção de imagem. No caso da coleção de imagens do Landsat 8, por exemplo, atribui-se a seguinte função: `ee.ImageCollection('LANDSAT/LC08/C01/T1_RT_TOA')`. Dessa forma, o GEE entenderá que, para o código (*script*) em questão deseja-se utilizar a coleção TOA do Landsat 8. Para a utilização de

apenas uma imagem durante a análise é preciso saber o código da imagem (ID) que se deseja utilizar. Para tanto, utiliza-se a função inspecionar (*inspector*) do GEE. E, clicando-se sobre a tela do mapa é possível analisar algumas informações das imagens para determinada região. Como por exemplo, dados de cobertura de nuvem, a data de aquisição da imagem, Datum, dentre outras informações.

O código geral para a utilização de apenas uma imagem segue um processo parecido para a declaração de uma variável utilizando-se uma coleção de imagens. Contudo, a declaração fica a seguinte: `ee.Image` ('LANDSAT/LC08/C01/T1_RT_TOA/LC08_221071_20130729'). Em relação à coleção de imagens, nota-se a diferença no ID da imagem ao final do nome (no exemplo citado, LC08_221071_20130729) e na declaração da variável utilizando-se a palavra *Image* sem a extensão *Collection*, que traria a coleção inteira. A figura 4.12 ilustra a diferença entre as duas formas de importar imagens.

```

NDWI_DF_comp_imagem_unica
1 Imports (1 entry)
2 var geometry: LinearRing, 31 vertices
3 // Aplicação inicial para identificar a melhor imagem a ser utilizada, no
4 // 0% de cobertura de nuvem
5 // var img = ee.ImageCollection("LANDSAT/LC08/C01/T1_RT_TOA")
6 // .filterBounds(geometry)
7 // .filterMetadata("CLOUD_COVER", 'less_than', 2);
8 // script utilizando apenas uma imagem
9 var img = ee.Image("LANDSAT/LC08/C01/T1_RT_TOA/LC08_221071_20130729");
10
11 var NDWI_veg = img.expression(
12   '(nir - swir) / (nir + swir)',
13   {
14     swir: img.select('B6'),
15     nir: img.select('B5'),
16   });
17
18 var NDWI_agua = img.expression(
19   '(green - nir) / (green + nir)',
20   {
21     green: img.select('B3'),
22     nir: img.select('B5'),
23   });
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100

NDWI_DF_colecao
10
11
12
13
14
15
16
17
18
19   green: image.select('B3'),
20   nir: image.select('B5'),
21 });
22 image = image.addBands(NDWI_agua.rename('NDWI_agua'));
23
24 return image;
25
26
27 // Coleção de imagens
28 var OLI = ee.ImageCollection("LANDSAT/LC08/C01/T1_RT_TOA")
29   .filterDate("2017-01-01", "2017-12-31")
30   .filterBounds(geometry)
31   .map(app);
32
33 // Make a palette: rampa de cor
34 var palette_a = ['070FFF', '37A314', 'FF8507', '00FFCF', '004EFF'];
35
36 // Gráficos
37 var lon = ui.Label();
38 var lat = ui.Label();
39
40 // Register a callback on the default map to be invoked when the map i
41 Map.onClick(function(coords)
42 {
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100

```

Figura 4.12 Declaração de variável para importação de imagem única e de uma coleção de imagem.

Para utilizar outras coleções basta realizar uma busca no campo de pesquisa e clicar em importar. Assim, a coleção de imagens é importada diretamente na página do código do GEE. Tal processo pode ser visto nas figuras 4.13 e 4.14.

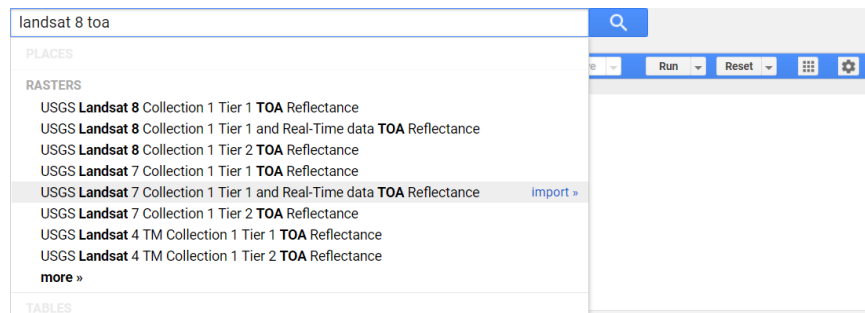


Figura 4.13 Busca de coleções de imagens do satélite Landsat.

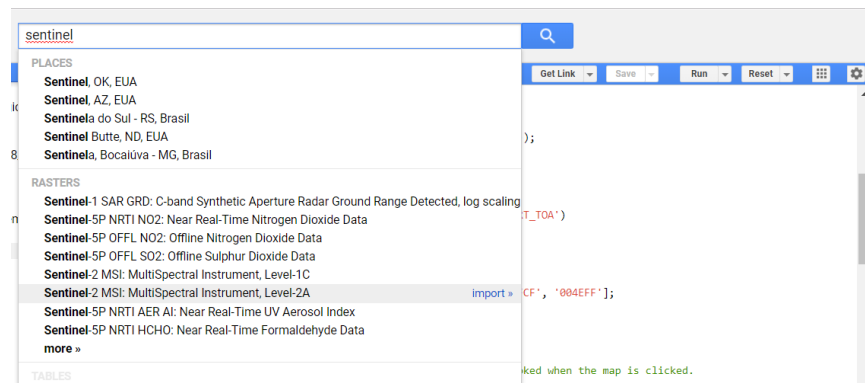


Figura 4.14 Busca de coleções de imagens do satélite Sentinel.

Além da possibilidade de importar as coleções de imagens, ao clicar sobre a coleção desejada é possível obter informações gerais sobre o satélite, as bandas disponibilizadas, o tempo de revisita das imagens, dentre diversas outras informações.

4.3.6 Função para Remoção de Nuvem

Os resultados gerados a seguir foram feitos para o ano de 2019 com o período de imagens que se tem disponível no próprio banco de dados do GEE, para a data presente de realização deste projeto. Para os resultados do RGB Sentinel – 2 A, o período utilizado foi do dia 01 janeiro de 2019 a 10 de maio de 2019 (Representação no código: '2019-01-01', '2019-05-10'). Para os resultados do Landsat 8, o período utilizado foi do dia 01 janeiro de 2019 a 04 de maio de 2019 (Representação no código: '2019-01-01', '2019-05-04').

A partir de uma mesma coleção de imagens para o mesmo período foi possível realizar o tratamento da composição de imagens na própria ferramenta. Ou seja, realizou-se a remoção da influência de nuvens que era bastante evidente no resultado final do mapa e que, portanto, atrapalhava a análise da imagem. Por meio de uma função que retorna imagens com menor percentual de nuvens foi possível chegar num resultado satisfatório, com um percentual de nuvens, na imagem composta, menor do que 10%. A função

utilizada para remoção de nuvens é declarada da seguinte forma: `filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))`. Essa função escolhe imagens, dentro do período selecionado, que possuam uma percentual de nuvens menor ou igual a 10% na imagem.

Para um resultado mais satisfatório em termos visuais, utilizou-se a função “*stretch: 100%*”, que retorna os valores mínimos e máximos presentes na imagem. Nas figuras 4.15 e 4.16 é possível comparar a imagem nos dois casos, menor influência de nuvens e maior influência de nuvens, tanto para o Sentinel – 2A, quanto para o Landsat 8. Os códigos desenvolvidos para as duas imagens encontram-se disponíveis nos apêndices C e D.

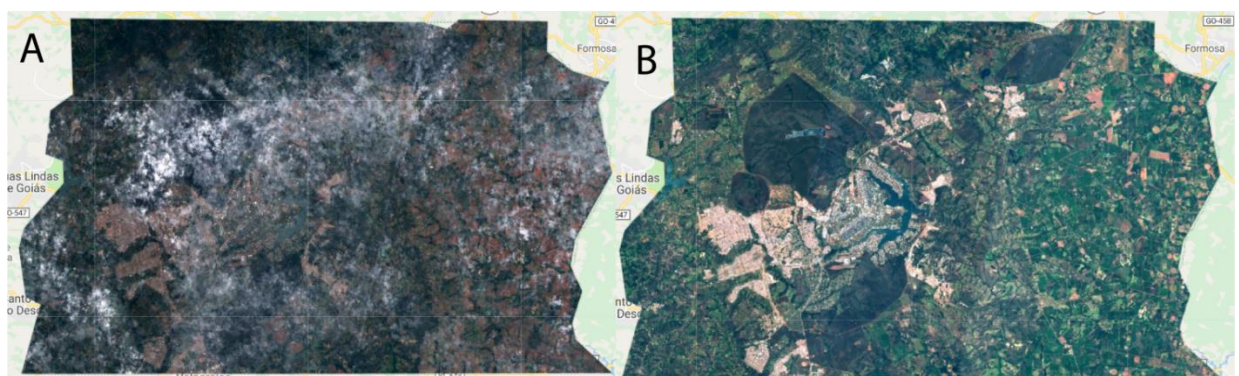


Figura 4.15 Em A tem-se a composição RGB sem a função de remoção de nuvens, em B tem-se a mesma imagem composta, contudo com a função de remoção de nuvens, ambas para o Sentinel – 2A.




Figura 4.16 Em A tem-se a composição RGB sem a função de remoção de nuvens, em B tem-se a mesma imagem composta, contudo com a função de remoção de nuvens, ambas para o Landsat 8.

4.3.7 Exportação de Imagens no GEE

O GEE apresenta a possibilidade de exportar imagens a partir da página de *script* das imagens disponíveis em seu banco de dados. Contudo, é necessário que o usuário apresente uma função específica para exportar a imagem desejada. Para exemplificar tal

função, a figura 4.17 apresenta o código ao final para exportar uma imagem RGB para o satélite Landsat 8. No apêndice D pode-se visualizar o código por completo.

```
34 Export.image.toDrive({  
35   image: composite.visualize({bands:['B4', 'B3', 'B2']})),  
36   description:'Landsat_8_RGB',  
37   scale: 30,  
38   region: geometry  
39 });  
40
```

Figura 4.17 Exportação de uma imagem RGB do satélite Landsat 8.

Conforme apresentado na figura 4.17, o código realiza a exportação considerando-se: qual imagem será exportada, no caso a composição RGB das bandas B4, B3 e B2; a descrição da imagem, que é o equivalente ao nome que será dado ao arquivo (*description*: 'Landsat_8_RGB'); a resolução de pixel de 30 m (*scale*: 30) e a região que será levada em conta na exportação, que no caso é a própria geometria em questão: a delimitação geográfica do DF (*region*: *geometry*). A função que fará a exportação é trazida por: "Export.image.toDrive({})". O arquivo final, neste caso, é enviado para a pasta do Google Drive sincronizada com a conta utilizada no GEE.

4.3.8 Comparação das Ferramentas

A partir da análise e da realização de alguns processamentos em ambas as ferramentas, com o enfoque em áreas de expansão urbana, comparou-se as potencialidades de cada uma delas. A comparação foi feita aplicando-se o uso da ferramenta QGIS.

Para que a comparação fosse equivalente em termos de resolução e parâmetros da imagem, utilizou-se imagens do Landsat 8 do mesmo período em que foram realizados os procedimentos no GEE. Comparou-se o QGIS com o GEE nos pontos a seguir:

1. Tempo gasto para baixar as imagens;
2. Tempo gasto para determinada operação entre Bandas. Cálculo de índices, por exemplo (calculou-se o NDVI para a comparação);
3. Processamento na nuvem (*online*);
4. Modificação no período da imagem durante o processamento; e
5. Composição em formato *Layout* para mapas.

Levando-se em conta o tempo de processamento, a depender do modelo de computador, o processamento no QGIS pode ser lento ou rápido. De maneira análoga no GEE, a depender da velocidade de internet, o processamento pode ser lento ou rápido.

5. RESULTADOS E DISCUSSÃO

Os tópicos a seguir foram resultados gerados a partir do desenvolvimento e programação de uma série de códigos no GEE, dentre eles: o código para o EVI, SAVI, NDWI, TRMM E NDBI. Os códigos para o NDVI e SRTM foram adaptações dos códigos pré-existentes no GEE.

5.1 PRIMEIRO TESTE: NDVI IMAGEM MODIS

O primeiro teste de processamento realizado foi o cálculo do índice NDVI, utilizando-se a coleção de imagens do satélite MODIS na data mencionada na metodologia. Pode-se perceber a partir da figura 5.1 que a resolução de pixel é baixa, sem contar a grande influência de nuvens da imagem capturada pelo satélite. Contudo, a demanda de processamento em nuvem é bem mais baixa do que a demanda do Landsat 8 ou Sentinel-2A, por exemplo. Portanto, a depender do tipo de resultado que se deseja, a coleção de imagens do MODIS pode ser uma boa saída, como por exemplo, o uso para escalas regionais ou continentais.



Figura 5.1 NDVI gerado para a imagem do Satélite MODIS.

5.2 MODELO DIGITAL DE ELEVAÇÃO – SRTM PARA O DF

A partir das imagens geradas a do SRTM pode-se obter o modelo digital de elevação para o DF. Na figura 5.2 é possível verificar as diferenças de cotas por meio das diferentes tonalidades de cinza, em que os tons mais claros são as cotas mais elevadas e os tons mais escuros são as cotas menos elevadas.




Figura 5.2 SRTM gerado para o DF.

Na figura 5.3 é possível visualizar os parâmetros gerados para o SRTM. Para o ajuste das cotas, utilizou-se o “*stretch: 100%*”, que retorna os valores mínimos e máximos referentes à imagem.

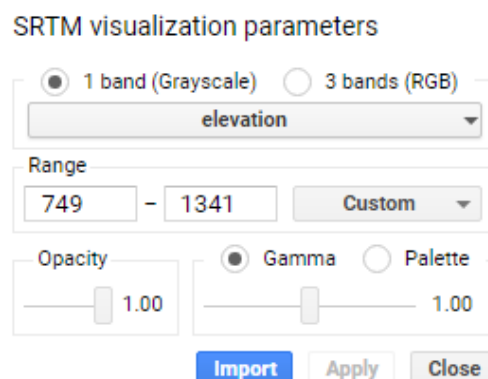


Figura 5.3 Visualização dos parâmetros gerados do SRTM para o DF.

Os resultados a seguir foram gerados a partir da coleção de imagens do Landsat 8 (TOA). O período utilizado para análise foi o conforme descrito na metodologia. Os Índices de vegetação gerados no GEE para o DF foram: NDVI, EVI, SAVI, NDWI e NDBI.

5.3 ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA – NDVI PARA O DF

A partir da equação 3.2, foi possível a realização do cálculo do NDVI para o DF, considerando-se o período entre 01 de janeiro de 2017 e 11 de setembro de 2017. O NDVI foi gerado a partir da imagem do Landsat 8 conforme apresentado no código (disponível no apêndice E). E com base no resultado mostrado na figura 5.4 é possível perceber que as áreas em verde mais escuro se encontram a vegetação mais exuberante, como as matas de galeria, matas ciliares e mais à Leste do DF, nas áreas agrícolas, os pivôs de irrigação. A partir desse resultado é possível verificar as diferenças entre área vegetada (em tons de verde) e não vegetada (em laranja e amarelo). Destas, as áreas não vegetadas se referem às áreas construídas ou provavelmente solo exposto.



Figura 5.4 NDVI gerado para o DF.

O NDVI ajustou-se melhor com o *stretch* por desvio padrão, utilizando-se o “3 σ ”. Para realizar essa configuração é necessário abrir a janela de visualização de parâmetros e escolher o tipo de alcance desejado. A partir da análise visual de aderência, comparando-se com a própria imagem do Landsat 8, a partir da qual foi gerado o índice, foi possível escolher qual *stretch* se ajustou melhor. Na figura 5.5 é possível visualizar os parâmetros utilizados para o NDVI, como por exemplo, o alcance computado, o *stretch* e a paleta de cores.

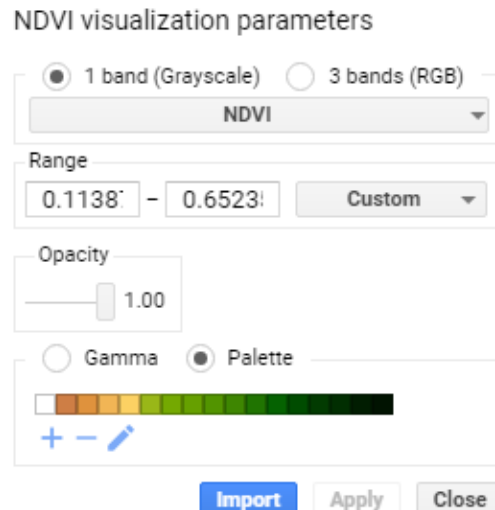


Figura 5.5 Visualização dos parâmetros do NDVI para o DF.

5.4 ÍNDICE DE VEGETAÇÃO AJUSTADO – EVI PARA O DF

Conforme exposto por Huete et al. (1997), este índice apresentou melhor desempenho do monitoramento da vegetação para regiões de alta biomassa, em que sua principal redução é em relação à influência do sinal advinda abaixo da cobertura vegetal, ou seja, possíveis refletâncias. A figura 5.6 mostra o resultado gerado para o EVI.



Figura 5.6 EVI gerado para o DF.

Os parâmetros ajustados para o EVI foram bem próximos do NDVI, além do ajuste ter sido melhor também com o *stretch* “3 σ ”.

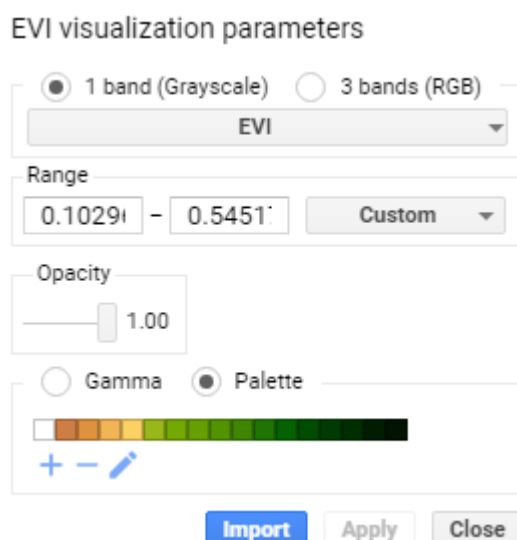


Figura 5.7 Visualização dos parâmetros do EVI para o DF.

5.5 ÍNDICE DE VEGETAÇÃO AJUSTADO AO SOLO – SAVI PARA O DF

Este índice, conforme proposto por Huete (1987), apresentou um melhor desempenho para áreas com pouca cobertura vegetal, ou seja, solo exposto. É possível perceber visualmente essas áreas de solo exposto, que podem ser identificadas pelas áreas mais alaranjadas e amareladas na parte direita da imagem. Na figura 5.8 é possível visualizar essas áreas.



Figura 5.8 SAVI gerado para o DF.

SAVI visualization parameters

☒ 1 band (Grayscale)
 ☐ 3 bands (RGB)

SAVI

Range

0.10521 - 0.38921

Stretch: 3 σ

Opacity

1.00

☐ Gamma
 ☒ Palette

+

-

Import Apply Close

Figura 5.9 Visualização dos parâmetros de SAVI para o DF.

A partir dos ajustes e da avaliação dos índices de NDVI, EVI e SAVI, percebeu-se por meio da análise visual que os 3 índices avaliados se ajustaram melhor com o *stretch* “3 σ ”.

5.6 ÍNDICE DE ÁGUA – NDWI PARA O DF

A figura 5.10 apresenta o resultado gerado de NDWI para o DF no mês de julho de 2018, em que se registrou o menor índice pluviométrico. Na figura, percebe-se visualmente que a região rural na parte leste estava mais úmida que as demais áreas. Essencialmente nas áreas compreendidas pelos pivôs de irrigação.




Figura 5.10 NDWI gerado para o DF, mês de julho 2018.




Figura 5.11 NDWI gerado para o DF, mês de dezembro 2018.

A partir das duas imagens geradas, pode-se notar que o índice NDWI teve uma aderência alta. Contudo, na figura 5.11 que representa o mês de dezembro é possível perceber que a imagem sofreu uma influência muito grande de nuvens devido à alta umidade presente nesse período. Como o índice foi avaliado dentro de um período de um mês, não foi possível utilizar a função de remoção de nuvens nesse caso.

No tópico a seguir, verificou-se a expansão da mancha urbana ao longo dos anos utilizando-se o índice NDBI. A fim de tornar a análise representativa, analisou-se um período de 20 anos, considerando-se imagens do Landsat 7, Landsat 8 e Sentinel – 2A.

5.7 DIFERENÇA NORMALIZADA PARA ÁREAS CONSTRUÍDAS – NDBI PARA O DF

O NDBI conforme proposto por Zha et al. (2003), foi adaptado para o *script* do GEE e os códigos estão disponíveis nos apêndices G, H e I. A partir dele foi possível gerar os resultados a fim de verificar a urbanização no DF. Realizou-se comparações com as imagens dos satélites Landsat 7, Landsat 8 e Sentinel – 2A. Os períodos analisados encontram-se na metodologia levantada no tópico 4.3. Nas imagens apresentadas nos subtópicos a seguir, pretendeu-se representar em vermelho as áreas construídas para diferenciar do restante.

5.7.1 NBDI com as Imagens do Landsat 7

Para as imagens do satélite Landsat 7 calculou-se o NBDI para os anos de 2000, 2010 e 2019. A aderência do índice à própria imagem do satélite se mostrou ruim, pois áreas como as de solo exposto também foram identificadas como áreas construídas pelo índice.




Figura 5.12 NBDI gerado para o DF a partir de imagens do satélite Landsat 7, 2000.

A coleção de imagens para o ano de 2010 retornou um NBDI satisfatório, apesar do cálculo do índice também ter sofrido influência de áreas com solo exposto. A figura 5.13 apresenta os resultados gerados para o ano de 2010.




Figura 5.13 NBDI gerado para o DF a partir de imagens do satélite Landsat 7, 2010.

O cálculo realizado para o ano de 2019 retornou uma imagem com bastante influência de nuvens. Apesar de ter utilizado no código uma composição de imagens com

porcentagem menor que 10%, a influência de nuvens nesse período foi alta. É possível observar tal influência no canto superior esquerdo da figura 5.14. Contudo, na mesma imagem é possível perceber também a influência que o índice NDBI sofre ao confundir áreas de solo exposto com área construída.




Figura 5.14 NBDI gerado para o DF a partir de imagens do satélite Landsat 7, 2019.

5.7.2 NDBI com as Imagens do Landsat 8

Ao realizar os cálculos dentro do código do GEE para retornar os valores de NDBI, obteve-se os resultados para os anos de 2013, 2017 e 2019. Contudo a aderência do índice nesses períodos não se mostrou muito boa. Da mesma forma que o índice NDBI sofreu influências nas imagens do satélite Landsat 7, a utilização das imagens do satélite Landsat 8 também mostraram sofrer influência nas áreas de solos expostos apresentados na imagem. Na figura 5.15 pode-se observar o resultado para o índice NDBI no período de 11 de abril a 31 de dezembro do ano de 2013 ('2013-04-11', '2013-12-31').




Figura 5.15 NDBI gerado para o DF a partir de imagens do satélite Landsat 8, 2013.

Nos cálculos realizados para o ano de 2017 ('2017-01-01', '2017-09-11') o índice NDBI mostrou sofrer uma influência maior, provavelmente por existirem mais áreas com solo exposto neste ano. No canto direito da figura 5.16 é possível visualizar essas áreas com o vermelho mais intenso do que no cálculo para o ano de 2013.




Figura 5.16 NDBI gerado para o DF a partir de imagens do satélite Landsat 8, 2017.

Para o ano de 2019 o período considerado para o cálculo foi menor do que os anos de 2013 e 2017 ('2019-01-01', '2019-05-10'). Provavelmente pelo período analisado não ter compreendido os meses de seca, o índice NDBI mostrou ter uma aderência melhor por não ter sofrido uma influência de áreas de solo exposto como nos anos de 2013 e 2017 conforme analisado anteriormente. Na figura 5.17 é possível visualizar o resultado gerado para o NDBI do ano de 2019.




Figura 5.17 NBDI gerado para o DF a partir de imagens do satélite Landsat 8, 2019.

5.7.3 NBDI com as Imagens do Sentinel – 2A.

Programou-se o código para o NBDI utilizando-se as imagens do satélite Sentinel – 2A para os anos de 2017 e 2019. O ano de 2017 aparentemente não retornou resultados gerados para a área do DF, somente o ano de 2019. O período analisado para o ano de 2019 foi de 01 de janeiro a 13 de maio ('2019-01-01', '2019-05-13').

A partir da figura 5.18 pode-se perceber que a aderência do índice NBDI à imagem do Sentinel-2A foi melhor que a do Landsat 8. Ao realizar a comparação da imagem RGB do próprio satélite, nota-se que a aderência foi boa, provavelmente pela resolução de pixel (B4 e B8, 10m. B11, 20 m) ser maior que a do Landsat 8 (30 m). Contudo, mesmo a resolução de pixel sendo melhor ainda houveram influências no índice gerado. Algumas áreas de solo exposto, por exemplo, o índice interpretou como área construída.




Figura 5.18 NBDI gerado para o DF a partir de imagens do satélite Sentinel – 2A.

5.8 COMPARAÇÃO DAS FERRAMENTAS QGIS E GEE

Para avaliar a ferramenta GEE nos quesitos levantados na metodologia, no tópico 4.3.8, calculou-se o NDVI utilizando-se a mesma composição de imagens do Landsat 8 para o mesmo período (01 de janeiro de 2017 e 11 de setembro de 2017) em que realizou-se os cálculos no GEE. A tabela 5.1 mostra os resultados dessas comparações. A partir dela observa-se que o GEE mostrou abranger grande parte das funcionalidades de um SIG tradicional, com a exceção da composição *layout* para mapas. Para tal funcionalidade ainda é dependente de outra ferramenta externa, como o QGIS.

Tabela 5.1 Comparações entre as ferramentas QGIS e GEE.

	QGIS	GEE
Baixar a imagem	Cerca de 40 minutos	Não necessita baixar imagens, o processamento é todo <i>online</i> dentro do <i>script</i>
Tempo gasto em operações aritméticas (NDVI)	~ 30 segundos	~ 5 segundos (internet de 15mb)
Processamento na nuvem (<i>online</i>);	Não possui essa funcionalidade	Todo o processamento é <i>online</i>
Modificação no período da imagem durante o processamento;	Necessidade de baixar as imagens novamente caso pretenda-se analisar outros períodos.	Modifica-se a linha de código para o novo período desejado
Composição em formato <i>layout</i> para mapas.	Sim, apresenta a composição em formato <i>layout</i> para mapas.	Não apresenta essa funcionalidade.

A partir do cálculo do NDVI em cada uma das ferramentas gerou-se os mapas ilustrados nas figuras 5.19 e 5.20. Para que a comparação do próprio índice não sofresse influência visual utilizou-se a mesma rampa de cor para as duas imagens.

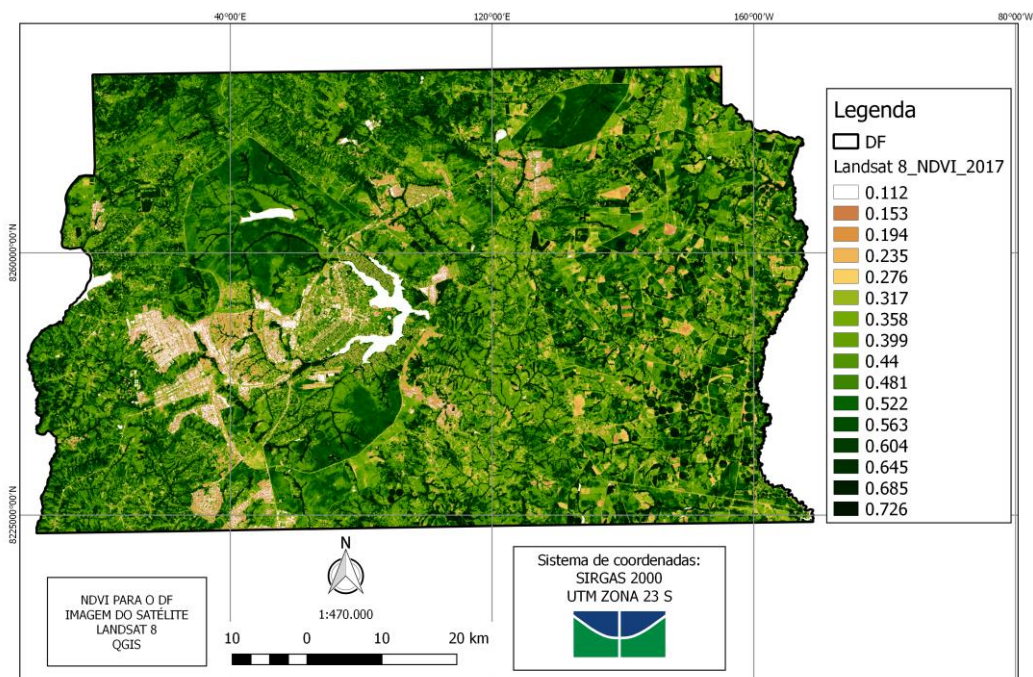


Figura 5.19 Mapa do NDVI gerado para o DF com o uso do QGIS.

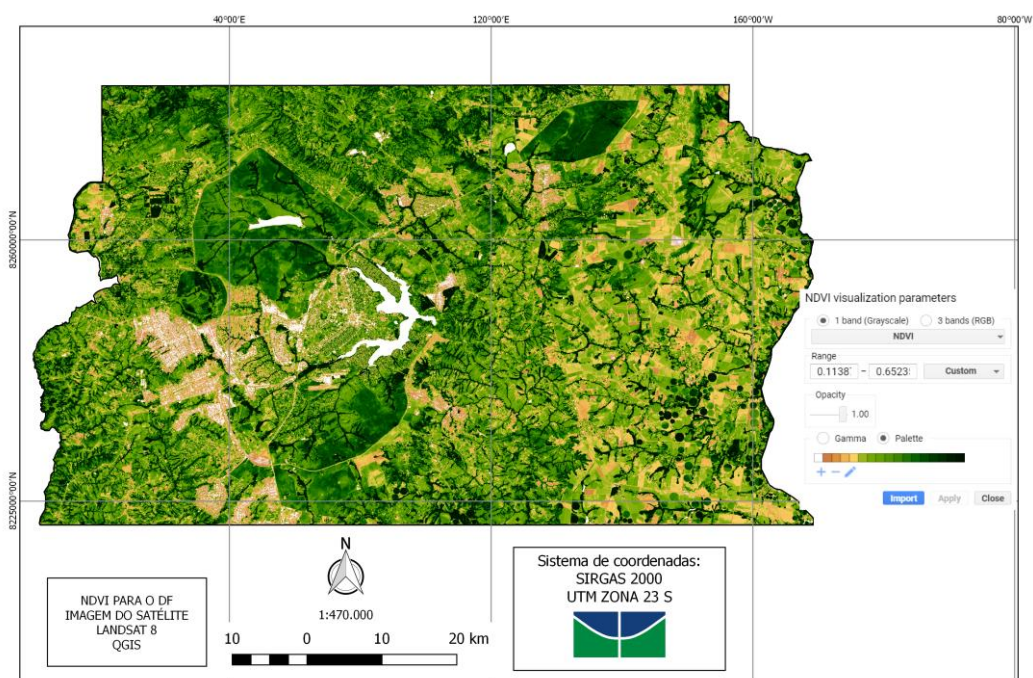


Figura 5.20 Mapa do NDVI gerado para o DF com o uso do QGIS para a imagem do GEE.

Comparando-se as duas imagens pode-se observar que existiram algumas divergências nos valores de NDVI calculados para cada ferramenta. No entanto, os valores entre o GEE e o QGIS foram próximos. Essa diferença no GEE pode ser causada pelo próprio ajuste do parâmetro dentro da ferramenta, pois como ele funciona por ajuste

dinâmico, a depender do nível de aproximação da imagem, o stretch pode retornar valores diferentes para o mesmo parâmetro, que neste caso foi o “3 σ ”. Este ajuste retornou os valores mínimos e máximos de 0.11388 e 0.65235, respectivamente.

5.9 VANTAGENS E DESVANTAGENS DO USO DA FERRAMENTA GEE

A partir da implementação dos códigos utilizados para o presente projeto e da comparação do uso do SIG tradicional, foi possível a identificação das vantagens e desvantagens do uso da ferramenta GEE. Como vantagens pode-se identificar as seguintes:

- A plataforma possui uma base de dados vasta de diversos satélites;
- O processamento é em nuvem (*online*);
- Possibilidade de compartilhamento em tempo real do *script*;
- Possibilita exportação para visualização em outros programas;
- Sua interface é muito simples e fácil de usar;
- O processamento independe do computador utilizado; e
- É possível a apresentação de gráficos dos valores/índices calculados.

O GEE também apresentou algumas desvantagens de uso, no entanto, elas não desvalorizam a ferramenta. A principal desvantagem quando comparado a um SIG tradicional é a aparente impossibilidade de visualização em formato de mapa. Essas desvantagens estão descritas abaixo:

- É necessário saber programação em JavaScript;
- O código é todo em inglês, mesmo utilizando-se a função de traduzir do Google;
- Aparentemente não faz montagem e/ou visualização em *Layout* de mapa; e
- Impossibilidade de trabalhar no código em modo *off-line*.

Após a identificação dessas vantagens e desvantagens foi possível elaborar a tabela 5.2 que as resume.

Tabela 5.2 Tabela de vantagens e desvantagens da ferramenta GEE.

VANTAGENS	DESVANTAGENS
Plataforma com base de dados e processamento em nuvem	É necessário saber programação em JavaScript
Compartilhamento em tempo real	O código é todo em inglês, mesmo utilizando-se a função de traduzir do Google

Possibilita exportação para visualização em outros programas	Aparentemente não faz montagem e/ou visualização em <i>Layout</i> de mapa
Interface muito simples e fácil de usar	Impossibilidade de trabalhar no código em modo <i>off-line</i>
Processamento independente do computador utilizado	
É possível a apresentação de gráficos dos valores/índices calculados	

Tendo em vista as vantagens que a ferramenta proporciona, pode-se verificar que a velocidade de obtenção dos resultados é a principal delas. Considerando-se que, atualmente, tem-se uma necessidade de aquisição de dados rapidamente, como o mapeamento da urbanização, uso e cobertura do solo, índice pluviométrico, dentre outros, o GEE mostrou ser uma ferramenta que pode auxiliar os mais diversos mapeamentos no Planeta.

Considerando-se o mesmo diagrama para os procedimentos gerais de um SIG tradicional na figura 4.2, a geração dos resultados no GEE e as comparações feitas entre o QGIS, foi possível verificar que os passos no GEE para processamento digital de imagens são semelhantes aos programas de SIG tradicionais.

Na figura 5.21 pode-se visualizar o diagrama para o GEE, em que a primeira etapa de baixar a imagem ou coleção de imagens para o processamento não é necessária, pois a base de dados já se encontra disponível dentro do sistema do GEE. Portanto, existe somente a necessidade de se realizar a importação da imagem ou coleção de imagens que se deseja utilizar.

As etapas descritas em verde são as etapas essenciais para a visualização no mapa do GEE. Contudo, as etapas descritas em amarelo são as etapas que dependem da necessidade do usuário e da própria necessidade de processamento. Na terceira etapa, por exemplo, que é a etapa de pré-processamento, pode-se realizar as correções na imagem antes ou após a importação e visualização da imagem em RGB.

De forma análoga, o contraste linear somente será aplicado se a composição da imagem necessitar desse procedimento. Da mesma forma, nos outros processos como a segmentação da imagem, as operações aritméticas e as transformações de imagens.

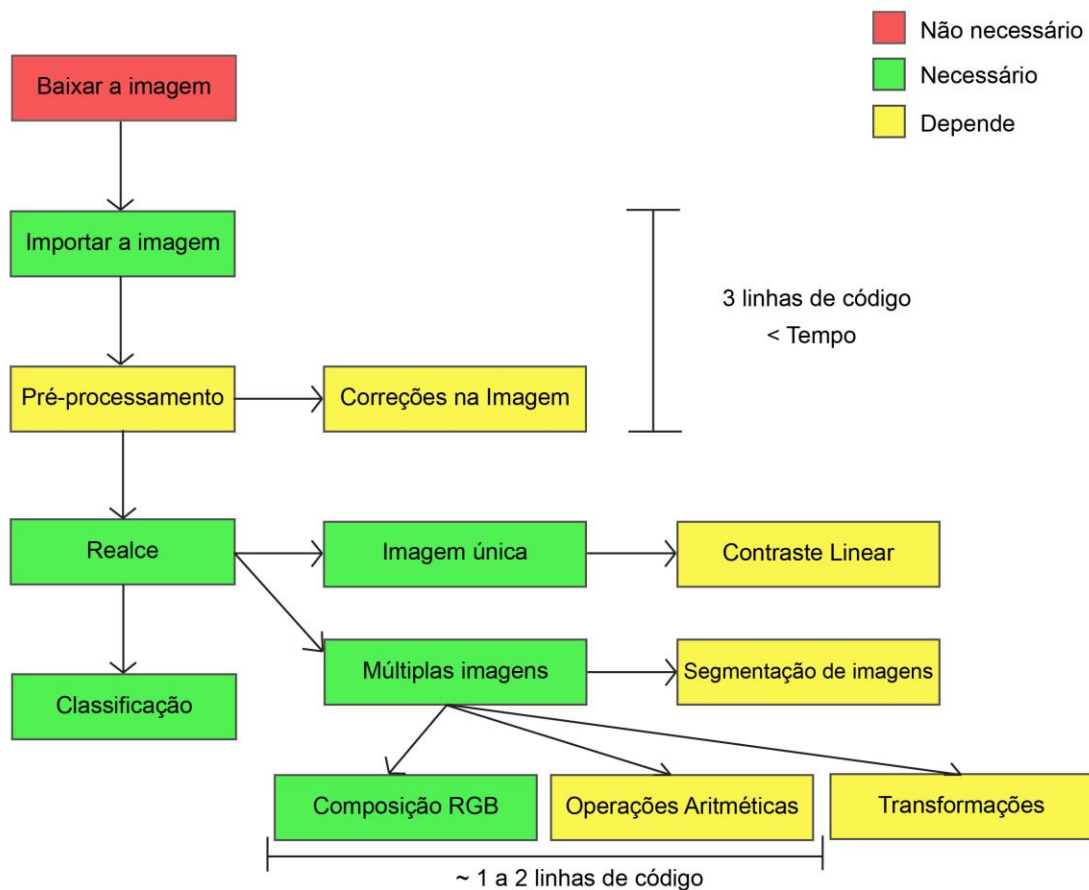


Figura 5.21 Passos para um processamento no GEE.

A partir dos resultados gerados no GEE e das comparações entre QGIS e GEE, é possível, contudo, avaliar a curva de aprendizagem durante a realização deste projeto. Sabendo-se dos requisitos para o aprendizado e a utilização da ferramenta GEE, o usuário que quiser começar a utilizá-la, poderá encontrar algumas dificuldades como a condição prévia de saber linguagem de programação, que no caso do GEE é em *JavaScript*. Além disso, é necessário o conhecimento prévio sobre geoprocessamento e o funcionamento das principais ferramentas de um programa de SIG.

6. CONCLUSÕES

O presente projeto possibilitou a análise da ferramenta GEE e suas possíveis contribuições para o monitoramento de áreas de expansão urbana, que a partir de uma série de índices de vegetação foi possível verificar presentes e futuras aplicações. Tal como o uso do índice NDBI para monitorar a urbanização, cujo índice foi o principal utilizado no presente trabalho para a análise.

A ferramenta GEE mostrou ser um indicativo de uma tendência no universo das ferramentas SIG, principalmente pela sua principal característica que é ser uma plataforma que facilite o uso e as aplicações para todos os usuários. A condição de ser uma plataforma *online* e possibilitar a interação simultânea de mais de um usuário ao mesmo tempo no mesmo código (página de *script*), faz com que ela abra caminho para as demais plataformas pensarem nessa implementação de programas SIG em formato *web*.

A partir da revisão de uma série de índices de vegetação e da programação dos códigos gerados no *script* do GEE foi possível notar que os resultados gerados durante a realização desse projeto se mostraram satisfatórios quando comparados com outras ferramentas de SIG, como por exemplo, o QGIS. A principal vantagem do GEE é ser uma ferramenta que utiliza o processamento via *online*, o que em relação ao QGIS mostrou ser mais rápido na geração de resultados e no carregamento da imagem. Tais funcionalidades concedem ao usuário do GEE um processamento de dados que não necessita de um computador dedicado. Portanto, o GEE mostra ser uma ferramenta que pode facilitar a análise visual de forma mais rápida do que uma ferramenta de SIG tradicional.

A linguagem de programação utilizada pelo GEE, apesar de simples, mostra-se bastante poderosa, pois foi desenvolvida numa Interface de Programação de Aplicativos (API). Essa interface que utiliza o formato em *JavaScript*, apresenta funcionalidades dinâmicas, o que permite a interação e modificação pelo usuário conforme sua necessidade. Por meio de controles intuitivos é possível ajustar rapidamente parâmetros da imagem conforme mencionados nos resultados. Contudo, a partir da janela de *script* é possível programar e adaptar os códigos já existentes da ferramenta. Dessa forma, existem diversas possibilidades, desde a declaração de uma simples variável até a composição de gráficos que podem ser dispostos na aba console ou abertos numa aba secundária, os chamados *pop-ups*.

O presente trabalho focou na utilização dos índices de vegetação para o auxílio no monitoramento da urbanização no DF. Entretanto, a ferramenta tem sido utilizada para inúmeros trabalhos, como por exemplo, a missão Global Forest Watch – uma iniciativa do World Resources Institute – que utiliza o GEE para medir e visualizar mudanças nas florestas do mundo. Esse mapeamento permite que o usuário sintetize dados da última década até o presente ou receba alertas sobre possíveis novas ameaças praticamente em tempo real. Algumas corporações, organizações sem fins lucrativos, governos e grupos indígenas vem utilizando a aplicação de forma tão diversa quanto a proteção contra a extração ilegal de madeira e a garantia na transparência da cadeia de alimentos.

Outro trabalho que vem utilizando a potencialidade da interface interativa da ferramenta é o The Map of Life team, que desenvolveu um mapa interativo para que os conservadores vejam e analisem as faixas de habitat para avaliar a segurança individual das espécies. Por meio da funcionalidade de selecionar ao apontar (*pinpointing*), o GEE retorna as localizações das espécies em risco. Os usuários podem ajustar os parâmetros (indicando, por exemplo, o habitat preferido de determinada espécie) e o GEE atualiza o mapa logo em sequência, mostrando-se o impacto na variação de espécies e na quantidade de habitat protegido.

No âmbito da análise ambiental, a ferramenta do GEE pode permitir ao usuário que sejam identificados corpos d'água e, conseqüentemente, identificar áreas de drenagem. O uso dos índices NDWI e NDBI, portanto, são de extrema relevância. Além disso, a combinação do uso dos índices podem gerar resultados mais específicos para a análise da urbanização e identificação de áreas impermeabilizadas.

Por fim, conforme as diversas funcionalidades que uma ferramenta de SIG proporciona como a possibilidade de realizar a classificação supervisionada e não supervisionada de imagens, fica como sugestão de trabalhos futuros a utilização da ferramenta GEE para a análise e classificação desses tipos de resultados.

REFERÊNCIAS BIBLIOGRÁFICAS

- BRASIL. Decreto Federal nº 4.297 de 10 de julho de 2002. Regulamenta o art. 9º, inciso II, da Lei nº 6.938, de 31 de agosto de 1981, estabelecendo critérios para o Zoneamento Ecológico-Econômico do Brasil - ZEE, e dá outras providências. Diário Oficial da União, 2002. Brasília: 11.07.2002. Disponível em: http://www.planalto.gov.br/ccivil_03/decreto/2002/d4297.htm. Acesso em: 10/11/2018.
- BRITO, Fausto; SOUZA, Joseane de. Expansão urbana nas grandes metrópoles: o significado das migrações intrametropolitanas e da mobilidade pendular na reprodução da pobreza. São Paulo em perspectiva, v. 19, n. 4, p. 48-63, 2005.
- BROGE, Niels Henrik; LEBLANC, Eric. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. Remote sensing of environment, v. 76, n. 2, p. 156-172, 2001.
- CHEN, Jing M. et al. Derivation and validation of Canada-wide coarse-resolution leaf area index maps using high-resolution satellite imagery and ground measurements. Remote sensing of environment, v. 80, n. 1, p. 165-184, 2002.
- CLEVERS, Jan GPW. Imaging spectrometry in agriculture-plant vitality and yield indicators. In: Imaging spectrometry – A tool for environmental observations. Springer, Dordrecht, 1994. p. 193-219.
- COLLINS, William. Remote sensing of crop type and maturity. Photogrammetric Engineering and Remote Sensing, v. 44, n. 1, p. 43-55, 1978.
- COLWELL, Robert N. Manual of Remote Sensing American Society of Photogrammetry. Falls Church, Virginia, 1983.
- COPQUE, AC da SM et al. Expansão urbana e redução de áreas verdes na localidade do Cabula VI Região do miolo da cidade do Salvador, Bahia. Anais XV Simpósio Brasileiro de Sensoriamento Remoto-SBSR, Curitiba, p. 706-713, 2011.
- COSTA, Heloísa Soares de Moura. Processos recentes de expansão metropolitana e implicações socioambientais: a experiência de Belo Horizonte. Direito urbanístico e política urbana no Brasil. Del Rey. Belo Horizonte. p. 387-406, 2001.

- DAUGHTRY, C. S. T. et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote sensing of Environment*, v. 74, n. 2, p. 229-239, 2000.
- DE BARCELLOS, Tanya M. Região Metropolitana de Porto Alegre: expansão urbana e dinâmica imobiliária nos anos 90. *Indicadores Econômicos FEE*, v. 32, n. 1, p. 65-90, 2004.
- EMBRAPA. SRTM – Shuttle Radar Topography Mission. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/srtm>>. Acesso em: 04/05/2019.
- ENGESAT. Landsat 8. Disponível em: <http://www.engesat.com.br/imagem-de-satelite/landsat-8/> Acesso em: 05/11/2018.
- ENGESAT. Sentinel-2. Disponível em: <http://www.engesat.com.br/imagem-de-satelite/landsat-8/> Acesso em: 05/11/2018.
- ESA. Observing the earth, Copernicus overview. Disponível em: http://www.esa.int/our_activities/observing_the_earth/copernicus/overview4 Acesso em: 30/10/2018.
- ESRI. About ArcGIS. Disponível em: <https://www.esri.com/en-us/arcgis/about-arcgis/overview> Acesso em: 28/11/2018.
- FITZ, Paulo R. Geografia tecnológica. Geoprocessamento sem complicação, Ed. Oficina de Textos. São Paulo, p. 19-29, 2008.
- FLORENZANO, T. G. Iniciação em Sensoriamento Remoto. 3a edição ed. São Paulo: Oficina de Textos, 2011. v. 3.
- GITELSON, Anatoly A. et al. Novel algorithms for remote estimation of vegetation fraction. *Remote sensing of Environment*, v. 80, n. 1, p. 76-87, 2002.
- GOOGLE EARTH ENGINE. Workspace. Disponível em: <https://code.earthengine.google.com>. Acesso em: 04/10/2018.
- GOOGLE EARTH SOLIDÁRIO. Introdução ao google earth engine. Disponível em: https://www.google.com/intl/pt-br/earth/outreach/tutorials/eartheng_gettingstarted.html. Acesso em: 04/10/2018.
- GOVERNO, DO DISTRITO FEDERAL. Lei de uso e ocupação do solo. Lei Complementar nº 948/2019. Brasília, 2019.

- GOVERNO, DO DISTRITO FEDERAL. Plano diretor de ordenamento territorial do Distrito Federal. Documento técnico. Brasília, 2009.
- GOVERNO, DO DISTRITO FEDERAL. Sobre Brasília: geografia. 2017. Disponível em: <<http://www.df.gov.br/333/>>. Acesso em: 29/05/2019.
- GOVERNO, DO DISTRITO FEDERAL. Zoneamento ecológico-econômico do Distrito Federal (ZEE – DF). Lei Distrital n° 6269/2019. Brasília, 2019.
- GROSTEIN, Marta Dora. Metrópole e expansão urbana: a persistência de processos "insustentáveis". São Paulo em perspectiva, v. 15, n. 1, p. 13-19, 2001.
- HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). Remote sensing of environment, v. 25, n. 3, p. 295-309, 1988.
- HUETE, Alfredo R.; LIU, Hui Qing. An error and sensitivity analysis of the atmospheric- and soil-correcting variants of the NDVI for the MODIS-EOS. IEEE Transactions on Geoscience and Remote sensing, v. 32, n. 4, p. 897-905, 1994.
- HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for MODIS-EOS. Remote Sens. Environ, v. 59, p. 440-451, 1997.
- HUNT JR, E. Raymond; ROCK, Barrett N.; NOBEL, Park S. Measurement of leaf relative water content by infrared reflectance. Remote sensing of environment, v. 22, n. 3, p. 429-435, 1987.
- IBGE. Brasília, panorama. Disponível em: <<https://cidades.ibge.gov.br/brasil/df/brasil/panorama>>. Acesso em: 29/05/2019.
- IBGE. Malhas digitais. Disponível em: <<https://mapas.ibge.gov.br/bases-e-referenciais/bases-cartograficas/malhas-digitais.html>>. Acesso em: 04/06/2019.
- IBGE. Shapefile DF. Disponível em: ftp://geoftp.ibge.gov.br/organizacao_do_territorio/malhas_territoriais/malhas_municipais/municipio_2015/ufs/df/ Acesso em: 22/11/2018.
- INPE. Geração de imagens. Disponível em: <http://www.dgi.inpe.br/documentacao/satelites/landsat#wrapper> Acesso em: 30/10/2018.

INPE. Descrição geral do SPRING. Disponível em: http://www.dpi.inpe.br/spring/portugues/tutorial/descricao_geral.html Acesso em: 28/11/2018.

JAPIASSÚ, Luana Andressa Teixeira; LINS, Regina Dulce Barbosa. As diferentes formas de expansão urbana. Revista Nacional de Gerenciamento de Cidades, v. 2, n. 13, 2014.

JACKSON, Thomas J. et al. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. Remote Sensing of Environment, v. 92, n. 4, p. 475-482, 2004.

JENSEN, John R.; EPIPHANIO, José Carlos Neves. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. Parêntese, 2011.

JOHNSON, Donald L. et al. Meanings of environmental terms. Journal of environmental quality, v. 26, n. 3, p. 581-589, 1997.

KARNIELI, Arnon et al. AFRI — Aerosol free vegetation index. Remote Sensing of Environment, v. 77, n. 1, p. 10-21, 2001.

KAUFMAN, Yoram J.; TANRE, Didier. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. IEEE transactions on Geoscience and Remote Sensing, v. 30, n. 2, p. 261-270, 1992.

KAUFMAN, Yoram J.; KARNIELI, Arnon; TANRÉ, Didier. Detection of dust over deserts using satellite data in the solar wavelengths. IEEE Transactions on Geoscience and Remote Sensing, v. 38, n. 1, p. 525-531, 2000.

KIM, Moon S. et al. The use of high spectral resolution bands for estimating absorbed photosynthetically active radiation (A par). 1994.

LIMA, Kássio MG et al. Sensores ópticos com detecção no infravermelho próximo e médio. Química Nova, 2009.

MELO, D. H. C. T. B. Uso de dados Ikonos II na análise urbana: testes operacionais na zona leste de São Paulo / D. H. C. T. B. Melo. - São José dos Campos: INPE, 2002. 146p. - (INPE-9865-TDI/870).

MENESES, P. R.; ALMEIDA, T. DE. Introdução ao processamento de imagem de sensoriamento remoto. 1a. ed. Brasília: UnB, 2012.

- NASA. TRMM – Tropical Rainfall Mission Measurement. Disponível em: <https://trmm.gsfc.nasa.gov/>. Acesso em: 05/06/2019.
- NOVO, E. M. M. Sensoriamento Remoto: princípios e aplicações. 2. ed. São Paulo: Edgard Blucher. 1988, 308 p.
- PATEL, Nirav N. et al. Multitemporal settlement and population mapping from Landsat using Google Earth Engine. International Journal of Applied Earth Observation and Geoinformation, v. 35, p. 199-208, 2015.
- PINA, M. de F.; SANTOS, Simone M. Conceitos básicos de Sistemas de Informação Geográfica e Cartografia aplicados à saúde. Brasília: OPAS, 2000.
- QGIS. QGIS – A liderança do SIG de código aberto. Disponível em: https://www.qgis.org/pt_BR/site/about/index.html. Acesso em: 28/11/2018
- RICHARDSON, Arthur J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. Photogrammetric engineering and remote sensing, v. 43, n. 12, p. 1541-1552, 1977.
- RONDEAUX, Geneviève; STEVEN, Michael; BARET, Frédéric. Optimization of soil-adjusted vegetation indices. Remote sensing of environment, v. 55, n. 2, p. 95-107, 1996.
- RUNDQUIST, Bradley C. The influence of canopy green vegetation fraction on spectral measurements over native tallgrass prairie. Remote Sensing of Environment, v. 81, n. 1, p. 129-135, 2002.
- SADECK, Luis. Google Earth Engine. Youtube. 2017. Disponível em: < <https://www.youtube.com/watch?v=Dqjtoj9AJak&list=PLNFvG6bTA4NReWtgC93Mh9Tw1RNG4EBMP&index=1>>. Acesso em: 16/11/2018.
- SANTORO, Paula Freire. Planejar a expansão urbana: dilemas e perspectivas. 2012. Tese de Doutorado. Universidade de São Paulo.
- SCHLERF, Martin; ATZBERGER, Clement; HILL, Joachim. Remote sensing of forest biophysical variables using HyMap imaging spectrometer data. Remote Sensing of Environment, v. 95, n. 2, p. 177-194, 2005.
- SCHOWENGERDT, Robert A. Techniques for image processing and classifications in remote sensing. Academic, New York, 1983.

- SECRETARIA DE DESENVOLVIMENTO URBANO E HABITAÇÃO DO DISTRITO FEDERAL, SEDUH – DF. Geoportal. 2019. Disponível em: <https://www.geoportal.seduh.df.gov.br/mapa/>. Acesso em: 22/05/2019.
- TERRACAP. Plano diretor de ordenamento territorial do Distrito Federal. Documento técnico. Brasília, 2009.
- TERRACAP. Plano diretor de ordenamento territorial – PDOT. Disponível em: <http://www.terracap.df.gov.br/regularizacao-fundiaria/areas-urbanas/plano-diretor-de-ordenamento-territorial-pdot>. Acesso em: 04/10/2018.
- VINCENT, S. P. R.; METCALFE, R. E.; TONG, D.P. Practical application of satellite remote sensing as a source of information for civil engineering projects and GIS. Proceedings of the Institution of Civil Engineers-Civil Engineering, v. 114, p. 35-43, Dec. 1996.
- ZHA, Yong; GAO, Jay; NI, Shaoxiang. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. International journal of remote sensing, v. 24, n. 3, p. 583-594, 2003.

APÊNDICES

A. SCRIPT DO NDVI PARA O DF, IMAGEM MODIS.

```

NDVI_DF_contorno_MODIS
Get Link Save Run Reset

Imports (1 entry)
  var geometry: Point (-47.82, -15.79)

1 // NormalizedDifference example.
2 //
3 // Compute Normalized Difference Vegetation Index over MOD09GA product.
4 // NDVI = (NIR - RED) / (NIR + RED), where
5 // RED is sur_refl_b01, 620-670nm
6 // NIR is sur_refl_b02, 841-876nm
7 // Create a FeatureCollection from a Fusion Table.
8
9 // Load a MODIS image.
10 var img = ee.Image('MODIS/006/MOD09GA/2012_10_10');
11
12 // Use the normalizedDifference(A, B) to compute (A - B) / (A + B)
13 var ndvi = img.normalizedDifference(['sur_refl_b02', 'sur_refl_b01']);
14
15 // Make a palette: a list of hex strings.
16 var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F1B555', 'FCD163', '99B718',
17               '74A901', '66A000', '529400', '3E8601', '207401', '056201',
18               '004C00', '023B01', '012E01', '011D01', '011301'];
19
20 // Center the map
21 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);
22
23
24 var df = ee.FeatureCollection('ft:1ptQ5np3QFiYNm1vUtGo2Yv-GEpbaHoBFwllT6Vdc');
25
26 var clip = ndvi.clipToCollection(df);
27
28 // Display the input image and the NDVI derived from it.
29 Map.addLayer(img.select(['sur_refl_b01', 'sur_refl_b04', 'sur_refl_b03']),
30             {gain: [0.1, 0.1, 0.1]}, 'MODIS bands 1/4/3');
31 Map.addLayer(clip, {min: 0, max: 1, palette: palette}, 'NDVI_DF');
32
33

```

B. SCRIPT SRTM PARA O DF.

```

SRTM_DF_
Get Link Save Run Reset

Imports (1 entry)
  var geometry: Polygon, 26 vertices

1 //----- Funções remover borda
2 var removerBorda = function(image){
3   var box = image.geometry();
4   return image.clip(box.buffer(-500.00));
5 };
6
7 // Display an image given its ID.
8
9 var image = ee.Image('CGIAR/SRTM90_V4');
10
11 var clip = image.clip(geometry);
12
13 // Center the map
14 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);
15 // Display the image.
16 Map.addLayer(clip, {min: 749, max: 1341}, 'SRTM');
17
18 // {min:920.507041673646, max: 1146.5064091612333}

```

C. COMPOSIÇÃO RGB PARA O SENTINEL – 2A.

```
_Sentinel_2_RGB *
Get Link Save Run Reset

Imports (1 entry)
var geometry: Polygon, 26 vertices

1 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);
2
3 //----- Funções remover borda
4 var removerBorda = function(image){
5   var box = image.geometry();
6   return image.clip(box.buffer(-500.00));
7 };
8
9 // Map the function over one year of data and take the median.
10 // Load Sentinel-2 TOA reflectance data.
11 var collection = ee.ImageCollection('COPERNICUS/S2')
12   .filterDate('2019-01-01', '2019-05-10')
13   // Pre-filter to get less cloudy granules.
14   .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
15
16
17 var composite = collection.median()
18 var clip = composite.clip(geometry)
19
20 // Display the results.
21 Map.addLayer(clip, {bands: ['B4', 'B3', 'B2'], min: 393, max: 1696}, 'Sentinel_2_RGB')
22
23 Export.image.toDrive({
24   image: clip.visualize({bands: ['B4', 'B3', 'B2'], min: 393, max: 1696}),
25   description: 'Sentinel_2_RGB_03_06',
26   scale: 10,
27   region: geometry
28 })
29
```

D. COMPOSIÇÃO RGB PARA O LANDSAT 8.

```
Landsat_8_RGB
Get Link Save Run Reset

Imports (1 entry)
var geometry: Polygon, 26 vertices

1 // Map the function over one year of data and take the median.
2 // Load Sentinel-2 TOA reflectance data.
3 var collection = ee.ImageCollection('LANDSAT/LC08/C01/T1_RT_TOA')
4   .filterDate('2019-01-01', '2019-05-04');
5
6 var maxcloudcover = 70;
7
8 /**
9  *Função para remover borda
10 */
11 var borderRemove = function(image){
12   var polygon = image.geometry();
13   return image.clip(polygon.buffer(-500.0));
14 };
15 /**
16  *Função para remover nuvens
17 */
18 var maskClouds = function(image) {
19   var scored = ee.Algorithms.Landsat.simpleCloudScore(image);
20   image = image.updateMask(scored.select(['cloud']).lt(10));
21   return borderRemove(image);
22 };
23
24
25 // Montando o Mosaico
26 collection = collection.filterBounds(geometry);
27 collection = collection.map(maskClouds);
28 var composite = collection.median();
29 var clip = composite.clip(geometry);
30
31 // Display the results.
32 Map.addLayer(clip, {bands: ['B4', 'B3', 'B2'], min: 0.04511098936200142, max: 0.1713637411594391}, 'Landsat_8_RGB');
33
34 Export.image.toDrive({
35   image: composite.visualize({bands: ['B4', 'B3', 'B2']}),
36   description: 'Landsat_8_RGB',
37   scale: 30,
38   region: geometry
39 });
```

E. ÍNDICES DE VEGETAÇÃO: NDVI, SAVI, EVI.

```
Indices_vegetacao_DF_Landsat_8_edit
```

```
import arcpy  
var geometry = LinearRing, 31 vertices  
  
1 |  
2 // Center the map  
3 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);  
4  
5 var removerBorda = function(image){  
6     var box = image.geometry();  
7     return image.clip(box.buffer(-600.00));  
8 };  
9  
10 var app = function (image)  
11 {  
12     //Índices de vegetação  
13     //Diferença Normalizada (NDVI)  
14     var ndvi = image.normalizedDifference(['B5', 'B4']);  
15     image = image.addBands(ndvi.rename('NDVI'));  
16  
17     //Índice por Diferença Normalizada para Áreas Construídas (NDBI)  
18     // NDBI = Bu - NDVI. Bu = NIR - SWIR / NIR + SWIR  
19     var ndbi = image.expression('((nir - swir) / (nir + swir)) - ((nir - red) / (nir + red))',  
20     {  
21         red: image.select('B4'),  
22         nir: image.select('B5'),  
23         swir: image.select('B6')  
24     });  
25     image = image.addBands(ndbi.rename('NDBI'));  
26  
27     //Índice de Vegetação Realçado (EVI)  
28     var evi = image.expression(  
29     '2.5 * (nir - red) / (nir + 6 * red - 7.5 * blue + 1)',  
30     {  
31         red: image.select('B4'),    // 620-670nm, RED  
32         nir: image.select('B5'),    // 841-876nm, NIR  
33         blue: image.select('B2')    // 459-479nm, BLUE  
34     });  
35     image = image.addBands(evi.rename('EVI'));  
36  
37     //Índice de Vegetação Ajustado ao Solo (SAVI)  
38     var savi = image.expression(  
39     '1.5 * (nir - red) / (nir + red + 0.5)',  
40     {  
41         red: image.select('B4'),    // 620-670nm, RED  
42         nir: image.select('B5'),    // 841-876nm, NIR  
43     });  
44     image = image.addBands(savi.rename('SAVI'));  
45  
46     return image;  
47 }  
48  
49 //Coleção de imagens  
50 var OLI = ee.ImageCollection('LANDSAT/LC08/C01/T1_RT_TOA')  
51   .filterDate('2017-01-01', '2017-09-11')  
52   .filterMetadata('CLOUD_COVER', 'LESS_THAN', 2)  
53   .filterBounds(geometry)  
54   .map(app);  
55  
56 // Make a palette: rampa de cor  
57 var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F18555', 'FC013D', '998718',  
58               '74A981', '66A000', '52A400', '3E8601', '207401', '056201',  
59               '10469C', '000000'];
```

```

56 // Make a palette: rampa de cor
57 var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F18555', 'FCD163', '998718',
58               '74A901', '66A000', '529400', '3E8601', '207401', '056201',
59               '004C00', '023801', '012E01', '011D01', '011301'];
60
61 //Gráficos
62 var lon = ui.Label();
63 var lat = ui.Label();
64
65 // Register a callback on the default map to be invoked when the map is clicked.
66 Map.onClick(function(coords)
67 {
68   // Update the lon/lat panel with values from the click event.
69   lon.setValue('lon: ' + coords.lon.toFixed(2));
70   lat.setValue('lat: ' + coords.lat.toFixed(2));
71
72   // Add a red dot for the point clicked on.
73   var point = ee.Geometry.Point(coords.lon, coords.lat);
74   var dot = ui.Map.Layer(point, {color: 'FF0000'});
75   Map.layers().set(1, dot);
76
77   // Create a Vegetation Index chart.
78   var chart = ui.Chart.image.series(OLI.select('NDVI', 'NDBI', 'EVI', 'SAVI'), point, ee.Reducer.mean(), 500);
79   chart.setOptions({
80     title: 'Índice de Vegetação',
81     vAxis: {title: 'Valores'},
82     hAxis: {title: 'TEMPO', format: 'MM-yy', gridlines: {count: 7}},
83   });
84
85   // Add the chart to the map.
86   chart.style().set({
87     position: 'bottom-right',
88     width: '500px',
89     height: '300px'
90   });
91   Map.add(chart);
92 }
93
94 var df = ee.FeatureCollection('ft:1ptQ5np3QfiYmM1vUtGo2Yv-GEpbaHo8Fw1t6V0c');
95 var clip = OLI.median().clipToCollection(df)
96
97 // Display the input image and the NDVI derived from it.
98 Map.addLayer(clip, {bands: 'B6,B5,B4'}, 'OLI');
99 Map.addLayer(OLI.median(), {min: 0.11387996104779324, max: 0.6523545179636785, bands: ['NDVI'], palette: palette}, 'NDVI', 0);
100 Map.addLayer(clip, {min: 0, max: 1, bands: ['NDBI'], palette: palette}, 'NDBI', 0);
101 Map.addLayer(OLI.median(), {min: 0.10296207580128985, max: 0.545175171950967, bands: ['EVI'], palette: palette}, 'EVI', 1);
102 Map.addLayer(OLI.median(), {min: 0.10520713144947377, max: 0.3892975525221771, bands: ['SAVI'], palette: palette}, 'SAVI');
103 //Map.addLayer(contornoDF, {}, 'Contorno_DF');
104
105 Export.image.toDrive({
106   image: clip.visualize({bands: ['EVI'], palette: palette, min: 0.06143004593770106, max: 0.7726181637120235}),
107   description: 'EVI_LANDSAT_8_DF_2',
108   scale: 30,
109   region: geometry
110 })
111

```

F. NDWI PARA O DF.

```

NDWI_DF_colecao_07_2018
Get Link Save Run Reset
Imports (1 entry)
var geometry: LinearRing, 31 vertices
1
2 // Center the map
3 Map.setCenter(-47.81830716965078, -15.791896717507273, 8);
4
5 var app = function (image)
6 {
7   //NDWI - Índice água
8   var NDWI_veg = image.expression(
9     '(nir - swir) / (nir + swir)',
10    {
11      swir: image.select('B6'),
12      nir: image.select('B5'),
13    });
14   image = image.addBands(NDWI_veg.rename('NDWI_veg'));
15
16   var NDWI_agua = image.expression(
17     '(green - nir) / (green + nir)',
18    {
19      green: image.select('B3'),
20      nir: image.select('B5'),
21    });
22   image = image.addBands(NDWI_agua.rename('NDWI_agua'));
23
24   return image;
25 }

```

```

27 //Coleção de imagens
28 var OLI = ee.ImageCollection ('LANDSAT/LC08/C01/T1_RT_TOA')
29   .filterDate('2018-07-01', '2018-07-31')
30   .filterBounds(geometry)
31   .map(app);
32
33 // Make a palette: rampa de cor
34 var palette_a = ['070FFF', '37A314', 'FF8507', '00FFCF', '004EFF'];
35
36 //Gráficos
37 var lon = ui.Label();
38 var lat = ui.Label();
39
40 // Register a callback on the default map to be invoked when the map is clicked.
41 Map.onClick(function(coords)
42 {
43   // Update the lon/lat panel with values from the click event.
44   lon.setValue('lon: ' + coords.lon.toFixed(2));
45   lat.setValue('lat: ' + coords.lat.toFixed(2));
46
47   // Add a red dot for the point clicked on.
48   var point = ee.Geometry.Point(coords.lon, coords.lat);
49   var dot = ui.Map.Layer(point, {color: 'FF0000'});
50   Map.layers().set(1, dot);
51
52   // Create a Vegetation Index chart.
53   var chart = ui.Chart.image.series(OLI.select('NDWI_agua','NDWI_veg' ), point, ee.Reducer.mean(), 500);
54   chart.setOptions({
55     title: 'NDWI',
56     vAxis: {title: 'Valores'},
57     hAxis: {title: 'TEMPO', format: 'MM-yy', gridlines: {count: 7}},
58   });
59
60   // Add the chart to the map.
61   chart.style().set({
62     position: 'bottom-right',
63     width: '500px',
64     height: '300px'
65   });
66   Map.add(chart);
67 });
68
69 // Display the input image and the NDVI derived from it.
70 Map.addLayer(OLI, {bands: 'B6,B5,B4'}, 'OLI');
71 Map.addLayer(OLI, {min: 0, max: 1, bands: ['NDWI_veg'], palette: palette_a}, 'NDWI_veg');
72 Map.addLayer(OLI, {min: -0.6924871286283569, max: 0.28137317299842834, bands: ['NDWI_agua'], palette: palette_a}, 'NDWI_agua');
73 //Map.addLayer(contornoDF, {}, 'Contorno_DF');
74
75
76
77

```

G. NDBI PARA O DF, LANDSAT 7

```

NDBI_DF_Landsat7_2019 *
Get Link Save Run Reset
Imports (1 entry)
  var geometry: LinearRing, 31 vertices
1
2 // Center the map
3 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);
4
5 var app = function (image)
6 {
7
8 //Índice por Diferença Normalizada para Áreas Construídas (NDBI)
9 // NDBI = Bu - NDVI. Bu = NIR - SWIR / NIR + SWIR
10 var ndbi = image.expression ('((nir - swir) / (nir + swir)) - ((nir - red) / (nir + red))',
11 {
12   red: image.select('B3'),
13   nir: image.select('B4'),
14   swir: image.select('B5')
15 });
16 image = image.addBands(ndbi.rename('NDBI'));
17
18 return image;
19 };
20

```

```

21 //Coleção de imagens
22 var OLI = ee.ImageCollection ('LANDSAT/LE07/C01/T1_RT_TOA')
23 // Pre-filter to get less cloudy granules.
24 .filterMetadata('CLOUD_COVER','LESS_THAN', 10)
25 .filterDate('2019-01-31', '2019-05-27')
26 .filterBounds(geometry)
27 .map(app);
28
29 var median = OLI.median();
30
31
32 // Make a palette: rampa de cor
33 var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F1B555', 'FCD163', '99B718',
34               '74A901', '66A000', '529400', '3E8601', '207401', '056201',
35               '004C00', '023B01', '012E01', '011D01', '011301'];
36
37 var palette_c = ['37A314','A8FF00','FF0000','FF8507','00FFCF','004EFF'];
38
39
40 var df = ee.FeatureCollection('ft:1ptQ5np3QFiYNm1vUtGo2Yv-GEpbaHoBFw11T6VDc');
41
42 var clipped = median.clipToCollection(df);
43
44 // Apresentação das Imagens
45 Map.addLayer(OLI, {bands:'B5,B4,B3'}, 'OLI');
46 Map.addLayer(clipped, {min: -0.4973, max: 0.3821, bands:['NDBI'], palette: palette_c}, 'NDBI');
47 OLI

```

H. NDBI PARA O DF, LANDSAT 8

The screenshot shows a code editor window titled "NDBI_DF_Landsat8_2019_". The code defines a function 'app' to calculate NDBI from Landsat 8 bands B4, B5, and B6. It then filters an ImageCollection of Landsat 8 TOA images for the period 2019-01-01 to 2019-06-12, based on a specific geometry. The script calculates the median of the filtered images and adds it to the map along with the original image collection.

```

NDBI_DF_Landsat8_2019_
Get Link Save Run Reset

Imports (1 entry)
var geometry: LinearRing, 31 vertices

1
2 // Center the map
3 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);
4
5 var app = function (image)
6 {
7
8 //Índice por Diferença Normalizada para Áreas Construídas (NDBI)
9 // NDBI = Bu - NDVI. Bu = NIR - SWIR / NIR + SWIR
10 var ndbi = image.expression ('((nir - swir) / (nir + swir)) - ((nir - red) / (nir + red))',
11 {
12   red: image.select('B4'),
13   nir: image.select('B5'),
14   swir: image.select('B6')
15 });
16 image = image.addBands(ndbi.rename('NDBI'));
17
18 return image;
19 };
20
21 //Coleção de imagens
22 var OLI = ee.ImageCollection ('LANDSAT/LC08/C01/T1_RT_TOA')
23
24 .filterDate('2019-01-01', '2019-06-12')
25 .filterBounds(geometry)
26 .map(app);
27
28 var median = OLI.median();

```

```

30 // Make a palette: rampa de cor
31 var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F1B555', 'FCD163', '99B718',
32               '74A901', '66A000', '529400', '3E8601', '207401', '056201',
33               '004C00', '023B01', '012E01', '011D01', '011301'];
34
35 var palette_c = ['37A314', 'A8FF00', 'FF0000', 'FF8507', '00FFCF', '004EFF'];
36
37 //Gráficos
38 var lon = ui.Label();
39 var lat = ui.Label();
40
41 // Register a callback on the default map to be invoked when the map is clicked.
42 Map.onClick(function(coords)
43 {
44   // Update the lon/lat panel with values from the click event.
45   lon.setValue('lon: ' + coords.lon.toFixed(2)),
46   lat.setValue('lat: ' + coords.lat.toFixed(2));
47
48   // Add a red dot for the point clicked on.
49   var point = ee.Geometry.Point(coords.lon, coords.lat);
50   var dot = ui.Map.Layer(point, {color: 'FF0000'});
51   Map.layers().set(1, dot);
52
53   // Create a Vegetation Index chart.
54   var chart = ui.Chart.image.series(OLI.select('NDBI'), point, ee.Reducer.mean(), 500);
55   chart.setOptions({
56     title: 'NDBI',
57     vAxis: {title: 'Valores'},
58     hAxis: {title: 'TEMPO', format: 'MM-yy', gridlines: {count: 7}},
59   });
60
61 // Add the chart to the map.
62 chart.style().set({
63   position: 'bottom-right',
64   width: '500px',
65   height: '300px'
66 });
67 Map.add(chart);
68 });
69
70 var df = ee.FeatureCollection('ft:1ptQ5np3QFiYnm1vUtGo2Yv-GEpbaHo8Fw11T6VDc');
71
72 var clipped = median.clipToCollection(df);
73
74
75 // Display the input image and the NDVI derived from it.
76 Map.addLayer(clipped, {min: 0.010712940245866776, max: 0.6200146079063416, bands: 'B6,B5,B4'}, 'OLI');
77 Map.addLayer(clipped, {min: -0.48220187425613403, max: 0.37805604934692383, bands: ['NDBI'], palette: palette_c}, 'NDBI');

```

I. NDBI PARA O DF, SENTINEL – 2A

```

NDBI_DF_Sentinel2_2019_
Get Link Save Run Reset
Imports (1 entry)
var geometry: LinearRing, 31 vertices
1 |
2 // Center the map
3 Map.setCenter(-47.81830716965078, -15.791896717507273, 10);
4
5 var app = function (image)
6 {
7
8 //Índice por Diferença Normalizada para Áreas Construídas (NDBI)
9 // NDBI = Bu - NDVI. Bu = NIR - SWIR / NIR + SWIR
10 var ndbi = image.expression ('((nir - swir) / (nir + swir)) - ((nir - red) / (nir + red))',
11 {
12   red: image.select('B4'),
13   nir: image.select('B8'),
14   swir: image.select('B11')
15 });
16 image = image.addBands(ndbi.rename('NDBI'));
17
18 return image;
19 };
20
21 //----- Funções remover borda
22 var removerBorda = function(image){
23   var box = image.geometry();
24   return image.clip(box.buffer(-500.00));
25 };
26
27 // Function to mask clouds using the Sentinel-2 QA band.
28 function maskS2clouds(image) {
29   var qa = image.select('QA60')
30
31   // Bits 10 and 11 are clouds and cirrus, respectively.
32   var cloudBitMask = 1 << 10;
33   var cirrusBitMask = 1 << 11;

```



```

35 // Both flags should be set to zero, indicating clear conditions.
36 var mask = qa.bitwiseAnd(cloudBitMask).eq(0).and(
37 | | | | qa.bitwiseAnd(cirrusBitMask).eq(0))
38
39 // Return the masked and scaled data, without the QA bands.
40 return image.updateMask(mask).divide(10000)
41 .select("B.*")
42 .copyProperties(image, ["system:time_start"])
43 }
44
45 //Coleção de imagens
46 var st = ee.ImageCollection('COPERNICUS/S2_SR')
47 .filterDate('2019-01-01', '2019-06-07')
48 .filterBounds(geometry)
49 // Pre-filter to get less cloudy granules.
50 .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
51 .map(maskS2clouds)
52 .map(app);
53
54 var median = st.median();
55
56 // Make a palette: rampa de cor
57 var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F1B555', 'FCD163', '998718',
58 '74A901', '66A000', '529400', '3E8601', '207401', '056201',
59 '004C00', '023801', '012E01', '011D01', '011301'];
60
61 var palette_inv = ['011301','011D01','012E01','023801','004C00','056201',
62 '207401','3E8601','529400','66A000','74A901','998718',
63 'FCD163','F1B555','DF923D','CE7E45','FFFFFF'];
64
65 var palette_c = ['37A314', 'A8FF00', 'FF8507', 'FF0000', '00FFCF', '00FFCF', '004EFF'];
66
67 //Gráficos
68 var lon = ui.Label();
69 var lat = ui.Label();
70
71 // Register a callback on the default map to be invoked when the map is clicked.
72 Map.onClick(function(coords)
73 {
74 // Update the lon/lat panel with values from the click event.
75 lon.setValue('lon: ' + coords.lon.toFixed(2));
76 lat.setValue('lat: ' + coords.lat.toFixed(2));
77
78 // Add a red dot for the point clicked on.
79 var point = ee.Geometry.Point(coords.lon, coords.lat);
80 var dot = ui.Map.Layer(point, {color: 'FF0000'});
81 Map.layers().set(1, dot);
82
83 // Create a Vegetation Index chart.
84 var chart = ui.Chart.image.series(st.select('NDBI'), point, ee.Reducer.mean(), 500);
85 chart.setOptions({
86 title: 'NDBI',
87 vAxis: {title: 'Valores'},
88 hAxis: {title: 'TEMPO', format: 'MM-yy', gridlines: {count: 7}},
89 });
90
91 // Add the chart to the map.
92 chart.style().set({
93 position: 'bottom-right',
94 width: '500px',
95 height: '300px'
96 });
97 Map.add(chart);
98 });
99
100 var df = ee.FeatureCollection('ft:1ptQ5np3QFiYVNm1wUtGo2Yv-GEpbaHo8Fw1IT6VDc');
101
102 var clipped = median.clipToCollection(df);
103
104
105 // Display the input image and the NDVI derived from it.
106 Map.addLayer(clipped, {min: 0.008200000040233135, max: 0.5559999942779541, bands:'B11,B8,B4'}, 'Sentinel_2');
107 Map.addLayer(clipped, {min: -0.6492633819580078, max: 0.560082197189331, bands:['NDBI'], palette: palette_c, 'NDBI');
108

```

J. TRMM para o DF, ano base 2018

```

TRMM_DF_2018 *
Get Link Save Run Reset

1 //Código para precipitação
2 // Usar o stretch por variância: 1 sigma
3
4 var trmm1 = ee.ImageCollection('TRMM/3B42').select('precipitation')
5   .filterDate('2018-01-01', '2018-01-31')
6   .mean();
7
8 var trmm2 = ee.ImageCollection('TRMM/3B42').select('precipitation')
9   .filterDate('2018-02-01', '2018-02-28')
10  .mean();
11
12 var trmm3 = ee.ImageCollection('TRMM/3B42').select('precipitation')
13   .filterDate('2018-03-01', '2018-03-31')
14   .mean();
15
16 var trmm4 = ee.ImageCollection('TRMM/3B42').select('precipitation')
17   .filterDate('2018-04-01', '2018-04-30')
18   .mean();
19
20 var trmm5 = ee.ImageCollection('TRMM/3B42').select('precipitation')
21   .filterDate('2018-05-01', '2018-05-31')
22   .mean();
23
24 var trmm6 = ee.ImageCollection('TRMM/3B42').select('precipitation')
25   .filterDate('2018-06-01', '2018-06-30')
26   .mean();
27
28 var trmm7 = ee.ImageCollection('TRMM/3B42').select('precipitation')
29   .filterDate('2018-07-01', '2018-07-31')
30   .mean();
31
32 var trmm8 = ee.ImageCollection('TRMM/3B42').select('precipitation')
33   .filterDate('2018-08-01', '2018-08-31')
34   .mean();
35
36 var trmm9 = ee.ImageCollection('TRMM/3B42').select('precipitation')
37   .filterDate('2018-09-01', '2018-09-30')
38   .mean();
39
40 var trmm10 = ee.ImageCollection('TRMM/3B42').select('precipitation')
41   .filterDate('2018-10-01', '2018-10-31')
42   .mean();
43
44 var trmm11 = ee.ImageCollection('TRMM/3B42').select('precipitation')
45   .filterDate('2018-11-01', '2018-11-30')
46   .mean();
47
48 var trmm12 = ee.ImageCollection('TRMM/3B42').select('precipitation')
49   .filterDate('2018-12-01', '2018-12-31')
50   .mean();
51
52 var df = ee.FeatureCollection('ft:1ptQ5np3QFiYNm1vUtGo2Yv-GEpbaHoBFw11T6VDC');
53 var clipped1 = trmm1.clipToCollection(df);
54 var clipped2 = trmm2.clipToCollection(df);
55 var clipped3 = trmm3.clipToCollection(df);
56 var clipped4 = trmm4.clipToCollection(df);
57 var clipped5 = trmm5.clipToCollection(df);
58 var clipped6 = trmm6.clipToCollection(df);
59 var clipped7 = trmm7.clipToCollection(df);
60 var clipped8 = trmm8.clipToCollection(df);
61 var clipped9 = trmm9.clipToCollection(df);
62 var clipped10 = trmm10.clipToCollection(df);
63 var clipped11 = trmm11.clipToCollection(df);
64 var clipped12 = trmm12.clipToCollection(df);
65
66 // LAYERS
67 Map.addLayer(clipped1, {bands:'precipitation', min: 0.211, max: 0.232, palette: ['FF8C00', '952CC7']}, 'JAN');
68 Map.addLayer(clipped2, {bands:'precipitation', min: 0.287, max: 0.309, palette: ['FF8C00', '952CC7']}, 'FEV');
69 Map.addLayer(clipped3, {bands:'precipitation', min: 0.215, max: 0.267, palette: ['FF8C00', '952CC7']}, 'MAR');
70 Map.addLayer(clipped4, {bands:'precipitation', min: 0.164, max: 0.181, palette: ['FF8C00', '952CC7']}, 'ABR');
71 Map.addLayer(clipped5, {bands:'precipitation', min: 0.014, max: 0.022, palette: ['FF8C00', '952CC7']}, 'MAIO');
72 Map.addLayer(clipped6, {bands:'precipitation', min: 0.000, max: 0.000, palette: ['FF8C00', '952CC7']}, 'JUN');
73 Map.addLayer(clipped7, {bands:'precipitation', min: 0.000, max: 0.000, palette: ['FF8C00', '952CC7']}, 'JUL');
74 Map.addLayer(clipped8, {bands:'precipitation', min: 0.018, max: 0.020, palette: ['FF8C00', '952CC7']}, 'AGO');
75 Map.addLayer(clipped9, {bands:'precipitation', min: 0.047, max: 0.053, palette: ['FF8C00', '952CC7']}, 'SET');
76 Map.addLayer(clipped10, {bands:'precipitation', min: 0.224, max: 0.258, palette: ['FF8C00', '952CC7']}, 'OUT');
77 Map.addLayer(clipped11, {bands:'precipitation', min: 0.352, max: 0.391, palette: ['FF8C00', '952CC7']}, 'NOV');
78 Map.addLayer(clipped12, {bands:'precipitation', min: 0.219, max: 0.294, palette: ['FF8C00', '952CC7']}, 'DEZ');
79 Map.centerObject(df);

```